

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Implementace modulárního zpracování biologických signálů

Modular Processing System for Biological Signals

2018

Bc. Martina Ládrová

Zadání diplomové práce

Student: **Bc. Martina Ládrová**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **Implementace modulárního zpracování biologických signálů**
Modular Processing System for Biological Signals
Jazyk vypracování: čeština

Zásady pro vypracování:

Diplomová práce se věnuje vybraným metodám zpracování jednorozměrných biologických signálů (např. EKG, EMG, FKG, BKG, apod.). Práce se zaměřuje na klasifikaci a popis vybraných metod (např. převzorkování, lineární filtrace – frekvenčně selektivní filtry, vlnková transformace, apod.) zpracování biologických signálů.

Cílem práce je vytvoření programu pro modulární zpracování s podporou výpočtových modulů a s konfigurovatelným způsobem zpracování jednotlivých výpočtů.

Postup řešení

1. Literární rešerše současného stavu problematiky zpracování (např. převzorkování, Notch filtr, Median filtr, frekvenčně selektivní filtry (DP, HP, PP, PZ), Lynnovy filtry, filtry založené na průměrování, vlnkové transformace, apod.) a analýzy (v časové a frekvenční oblasti) jednorozměrných biologických signálů.
2. Klasifikace a matematický popis vybraných metod zpracování.
3. Návrh a realizace programu modulárního zpracování biologických signálů (tj. generování signálů, převzorkování signálů, filtrace (předzpracování) signálů, analýza v časové a frekvenční oblasti, ukládání, verifikace použitých metod, apod.). Pro ověření funkčnosti jednotlivých modulů navržené architektury bude využito prostředí Matlab nebo LabVIEW.
4. Implementace architektury pro modulární zpracování signálu pomocí .NET Frameworku ve spolupráci s firmou CertiCon a.s.
5. Ověření funkčnosti navrženého programu na syntetických i reálných datech.
6. Diskuze dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] RANGAYYAN, Rangaraj M., METIN AKAY, ed. *Biomedical signal analysis*. Second edition. Hoboken: Wiley, 2015. ISBN 978-0-470-91139-6..
- [2] CHANG, Hsun-Hsien; MOURA, José MF. *Biomedical signal processing*. Biomedical Engineering and Design Handbook. McGraw Hill (June 2009), 2010, 559-579.
- [3] SMITH, Steven. *Digital signal processing: a practical guide for engineers and scientists*. Elsevier Science & Technology, 2013. ISBN 978-0750674447.
- [4] MARTINEK, Radek. *Využití komplexních adaptivních metod zpracování signálů pro zpřesnění diagnostické kvality abdominálního fetálního elektrokardiogramu*. Ostrava, 2014. Disertační práce. Vysoká škola báňská - Technická univerzita Ostrava, Fakulta elektrotechniky a informatiky.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **doc. Ing. Radek Martinek, Ph.D.**

Konzultant diplomové práce: Petr Foltýnek

Ing. Jaromír Konečný, Ph.D.

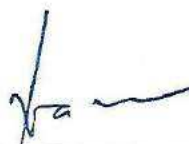

doc. Ing. Martin Černý, Ph.D.

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jiří Koziolek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

„Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.“

V Ostravě dne 30. 4. 2018

Podpis



Na tomto místě bych ráda poděkovala vedoucímu práce doc. Ing. Radkovi Martinkovi, Ph.D. za poskytnuté odborné rady, trpělivost a čas, který mi během řešení práce poskytl. Poděkování patří také Ing. Jaromírovi Konečnému, Ph.D. za odbornou pomoc při programování.

Abstrakt

Biologický signál je signálem velmi křehkým, proto jsou stále hledány nové a zlepšovány již objevené metody jeho zpracování. Diplomová práce se tímto zpracováním biologických signálů zabývá, klasifikuje jejich způsoby měření, problematiku rušení a metody zpracování, kdy vychází z poznatků současné literatury. Náplní práce je návrh softwaru pro zpracování nejčastěji využívaných biologických signálů v diagnostice (EKG, EEG, EMG, PPG, FKG) a jeho implementace v Matlabu. Software je vytvořen s cílem pojmout co největší oblast zpracování biologických signálů tak, aby bylo možné provést základní úpravy, popř. analýzu jakéhokoli jednorozměrného biologického signálu.

Klíčová slova

Biologický signál, měření biologických signálů, rušení v biologických signálech, zpracování biologických signálů, filtrace biologických signálů, EKG, EEG, EMG, PPG, FKG

Abstract

A biological signal is a weak signal, so it is necessary to find new or improve methods of its processing. The diploma thesis deals with the processing of biological signals and classifies the ways of their measurement, problems of their interference and methods of processing, based on the contemporary literature. The content of the paper is the design of software for processing the most commonly used biological signals in diagnostics (ECG, EEG, EMG, PPG, PCG) and its implementation in Matlab. The software is designed to ensure the greatest possible area of the biological signal processing so that basic modifications or analysis of any one-dimensional biological signal can be made.

Key Words

Biological signal, biological signal measurement, biological signal interference, biological signal processing, biological signal filters, ECG, EEG, EMG, PPG, PCG

Obsah

Seznam použitých zkratk.....	9
Seznam obrázků	11
Seznam tabulek	14
Úvod.....	15
1. Klasifikace měřených signálů	16
1.1. EKG (elektrokardiogram).....	16
1.1.1. Standardy měření EKG	16
1.1.2. EKG křivka	18
1.1.3. Rušení v signálu EKG	19
1.1.4. Metody zpracování EKG.....	20
1.2. EEG (elektroencefalogram).....	21
1.2.1. Standardy měření EEG.....	21
1.2.2. EEG záznam.....	22
1.2.3. Rušení v EEG záznamu.....	23
1.2.4. Metody zpracování EEG	24
1.3. EMG (elektromyogram).....	25
1.3.1. Měření EMG	25
1.1.1. EMG záznam.....	25
1.1.2. Rušení EMG signálu	27
1.1.3. Metody zpracování EMG	28
1.2. FKG (fonokardiogram)	29
1.2.1. Měření FKG	29
1.2.2. FKG záznam.....	29
1.2.3. Rušení v FKG signálu	30
1.2.4. Metody zpracování FKG.....	30
1.3. PPG (fotopletysmograf)	32
1.3.1. Měření PPG.....	32
1.3.2. Pulsová vlna	32
1.3.3. Rušení v PPG signálu.....	32
1.3.4. Metody zpracování PPG.....	33
2. Metody zpracování signálů	34

2.1.	Převzorkování signálu	34
2.2.	Filtrace ve frekvenční oblasti	36
2.2.1.	IIR filtr	37
	Butterworthův filtr	37
	Notch filtr	39
2.2.2.	FIR filtr	40
2.3.	Filtrace v časové oblasti	43
2.3.1.	Synchronizované průměrování	43
2.3.2.	Klouzavý průměr	43
2.3.3.	Derivace signálu	44
2.4.	Adaptivní filtrace	44
2.4.1.	Adaptivní filtr s fázovým závěsem	44
2.5.	Separace signálů z jejich kombinace	45
2.5.1.	PCA	46
2.5.2.	ICA	46
2.6.	Vlnková transformace	47
2.7.	EMD	48
3.	Aplikace pro zpracování biologických signálů	49
3.1.	Funkce GUI	50
3.2.	Modul úpravy signálu	52
3.3.	Načtení signálu	53
3.4.	Převzorkování signálu	54
3.5.	Rušení signálu	54
3.5.1.	Síťové rušení	54
3.5.2.	Nízkofrekvenční drift	55
3.5.3.	Trendy	55
3.5.4.	Náhodný šum	57
3.5.5.	Bílý šum	57
3.6.	Filtrace signálu	58
3.6.1.	FIR filtr	58
3.6.2.	IIR filtr	60
3.6.3.	Notch filtr	61
3.6.4.	Klouzavý průměr	63

3.6.5.	ANC	64
3.7.	Metody zpracování signálu	65
3.7.1.	Derivace	65
3.7.2.	WT.....	67
3.7.3.	PCA	68
3.7.4.	ICA	70
3.7.5.	EMD.....	72
3.8.	Analýza signálu	74
3.8.1.	Detektor vrcholů EKG a FKG.....	75
3.8.2.	Detektor vrcholů PPG	78
3.8.3.	Analýza EEG.....	79
3.8.4.	Analýza EMG.....	80
3.9.	Ukázka implementace do jazyka C#	81
4.	Experimentální porovnání metod zpracování signálu	88
4.1.	Odstranění síťového rušení	88
4.1.1.	FIR filtrace	91
4.1.2.	IIR filtrace	96
4.1.3.	ANC filtrace	101
4.1.4.	WT.....	106
4.2.	Odstranění náhodného šumu	111
4.3.	Odstranění artefaktů	113
4.4.	Separace signálů	116
4.4.1.	Syntetická data	116
4.4.2.	Reálná data	117
	Závěr	121
	Literatura.....	122
	Seznam příloh	125

Seznam použitých zkratek

Zkratka	Význam česky	Význam anglicky
ANC	Adaptivní filtr s fázovým závěsem	Adaptive Noise Cancellor
ANS	Autonomní nervový systém	
B-A graf	Blandův-Altmanův graf	
BSS	Separace slepých zdrojů	Blind Source Separation
CMAP	Sumační akční potenciál svalu	Compound Muscle Action Potential
CWT	Spojité vlnková transformace	Continous Wavelet Transform
DFT	Diskrétní Fourierova transformace	
DP	Dolní propust	
DWT	Diskrétní vlnková transformace	
EEG	Elektroencefalograf	
EKG	Elektrokardiograf	
EMD	Empirická modální dekompozice	
EMG	Elektromyograf	
EOG	Elektrookulografie	
EP	Evokované potenciály	
FFT	Rychlá Fourierova transformace	Fast Fourier Transform
FIR	Konečná impulsní charakteristika	Finite Impulse Response
FKG	Fonokardiograf	
FT	Fourierova transformace	
HP	Horní propust	
ICA	Analýza nezávislých komponent	Indipendent Component Analysis
IIR	Nekonečná impulsní charakteristika	Infinite Impulse Response

IMF	Vlastní modální funkce	Intrinsic Mode Function
MSE	Střední kvadratická chyba	Mean Squared Error
MUAP	Akční potenciál motorické jednotky	Motor Unit Action Potential
PCA	Analýza hlavních komponent	Principle Component Analysis
PP	Pásmová propust	
PPG	Fotopletysmograf	Photoplethysmograph
PZ	Pásmová zádrž	
RLS		Recursive Least Squares
SD	Směrodatná odchylka	Standard Deviation
SNR	Poměr výkonu signálu k šumu	Signal to Noise Ratio
WT	Vlnková transformace	Wavelet Transform

Seznam obrázků

Obrázek 1: Einthovenův trojúhelník.....	17
Obrázek 2: Rozmístění hrudních elektrod.....	17
Obrázek 3: EKG křivka v časové oblasti.....	18
Obrázek 4: Parametry EKG signálu ve frekvenční oblasti.....	19
Obrázek 5: Vlna DB4.....	21
Obrázek 6: Rozmístění EEG elektrod dle systému 10–20 při pohledu na lebku shora.....	22
Obrázek 7: Příklad EEG signálu a jeho rozložení na jednotlivé rytmy.....	23
Obrázek 8: Rozdělení pásem EEG ve frekvenční oblasti.....	23
Obrázek 9: Příklady akčních potenciálů různých motorických jednotek (MUAP).....	26
Obrázek 10: Příklad EMG měřeného povrchově.....	26
Obrázek 11: Příklad frekvenčního spektra povrchově měřeného EMG.....	27
Obrázek 12: Průběh FKG signálu a jeho souvislost s EKG křivkou.....	30
Obrázek 13: Průběh periferní pulsové vlny.....	32
Obrázek 14: Příklad interpolace nejbližším sousedem.....	35
Obrázek 15: Příklad lineární interpolace.....	35
Obrázek 16: Příklad kubické a spline interpolace.....	36
Obrázek 17: Frekvenční charakteristika Butterworthova filtru.....	38
Obrázek 18: Frekvenční charakteristika Čebyševova filtru I.....	38
Obrázek 19: Frekvenční charakteristika Čebyševova filtru II.....	39
Obrázek 20: Frekvenční charakteristika eliptického filtru.....	39
Obrázek 21: Frekvenční charakteristika Notch filtru.....	40
Obrázek 22: Frekvenční charakteristika FIR filtru – Hammingovo okno.....	41
Obrázek 23: Frekvenční charakteristika FIR filtru – Blackmanovo okno.....	42
Obrázek 24: Frekvenční charakteristika FIR filtru – Hannovo okno.....	42
Obrázek 25: Frekvenční charakteristika FIR filtru – Bartlettovo okno.....	42
Obrázek 26: Blokový diagram funkce ANC.....	45
Obrázek 27: Příklad mateřských vlnek.....	48
Obrázek 28: UML diagram aplikace.....	50
Obrázek 29: GUI aplikace.....	51
Obrázek 30: UML diagram modulu úpravy signálu.....	52
Obrázek 31: GUI modulu načtení signálu – celý signál.....	53
Obrázek 32: GUI modulu načtení signálu – vybraný úsek a zvolené kanály.....	53
Obrázek 33: Příklad síťového rušení v signálu EKG (frekvence 50 Hz, amplituda 0,1).....	54
Obrázek 34: Příklad kolísání izolinie v signálu EKG (frekvence 0,2 Hz, amplituda 0,3).....	55
Obrázek 35: Příklad lineárního trendu v signálu EKG (posun 3, strmost 0,2).....	56
Obrázek 36: Příklad Gaussovského trendu v signálu EKG (pozice vrcholu 4, šířka 2).....	56
Obrázek 37: Příklad rušení myopotenciály v signálu EKG (časový úsek 5,1 – 5,6 s a 3,5 – 3,7 s, amplituda 0,2).....	57
Obrázek 38: Příklad bílého šumu v signálu EKG (výkon šumu -25 dB).....	58
Obrázek 39: Příklad FIR filtrace signálu EMG (PP, Hammingovo okno, mezní frekvence 50 a 150 Hz, řád filtru 100).....	59
Obrázek 40: Vývojový diagram FIR filtru.....	59

Obrázek 41: Příklad IIR filtrace signálu FKG – odstranění bílého šumu (DP, Butterworth, mezní frekvence 500 Hz, řád filtru 10).....	60
Obrázek 42: Vývojový diagram IIR filtru.....	61
Obrázek 43: Příklad notch filtrace signálu EMG – odstranění síťového rušení (mezní frekvence 50 Hz, řád 50).....	62
Obrázek 44: Vývojový diagram notch filtru.....	62
Obrázek 45: Příklad filtrace klouzavým průměrem signálu PPG – odstranění myopotenciálů (řád filtru 20).....	63
Obrázek 46: Vývojový diagram klouzavého průměru.....	63
Obrázek 47: Příklad ANC filtrace signálu abdominálního EKG (řád filtru 10, referenční signál hrudního EKG matky).....	64
Obrázek 48: Vývojový diagram ANC filtru.....	65
Obrázek 49: Příklad derivace signálu EKG.....	66
Obrázek 50: Vývojový diagram derivace signálu.....	66
Obrázek 51: Příklad WT signálu FKG (vlnka sym10, úroveň rozkladu 9).....	67
Obrázek 52: Vývojový diagram WT.....	68
Obrázek 53: Příklad hlavních komponent abdominálního EKG signálu (PC1 odpovídá EKG signálu matky, PC2 pak signálu plodového EKG).....	69
Obrázek 54: Vývojový diagram PCA.....	69
Obrázek 55: Příklad nezávislých komponent abdominálního EKG signálu (IC2 nejlépe odpovídá signálu plodového EKG).....	70
Obrázek 56: Vývojový diagram fastICA.....	71
Obrázek 57: Příklad metody EMD na signálu EEG – odstranění lineárního trendu (počet IMF = 10).....	72
Obrázek 58: Vývojový diagram EMD.....	73
Obrázek 59: UML diagram modulu analýzy signálu.....	74
Obrázek 60: Příklad modulu analýzy EKG.....	75
Obrázek 61: Vývojový diagram detekce vrcholů s pevným prahem.....	76
Obrázek 62: Vývojový diagram adaptivního detektoru vrcholů.....	77
Obrázek 63: Příklad derivace signálu PPG.....	78
Obrázek 64: Porovnání detekce vrcholů z původního (nahore) a derivovaného (dole) signálu PPG.....	78
Obrázek 65: Příklad modulu analýzy EEG.....	80
Obrázek 66: Příklad modulu analýzy EMG.....	81
Obrázek 67: : UML diagram aplikace v C#.....	82
Obrázek 68: GUI aplikace v C#.....	83
Obrázek 69: Generovaný signál EKG s přidaným šumem.....	84
Obrázek 70: B-A grafy IIR filtrace vůči původnímu signálu EKG.....	85
Obrázek 71: B-A grafy FIR filtrace vůči původnímu signálu EKG.....	86
Obrázek 72: B-A grafy filtrace klouzavým průměrem vůči původnímu signálu EKG.....	87
Obrázek 73: Původní EKG a EKG s přidaným šumem v časové a frekvenční oblasti.....	88
Obrázek 74: Původní EEG a EEG s přidaným šumem v časové a frekvenční oblasti.....	89
Obrázek 75: Původní EMG a EMG s přidaným šumem v časové a frekvenční oblasti.....	90
Obrázek 76: Původní FKG a FKG s přidaným šumem v časové a frekvenční oblasti.....	90

Obrázek 77: Původní PPG a PPG s přidaným šumem v časové a frekvenční oblasti.....	91
Obrázek 78: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu EKG.	92
Obrázek 79: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu EEG.....	93
Obrázek 80: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu EMG.....	94
Obrázek 81: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu FK G.....	95
Obrázek 82: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu PPG.	96
Obrázek 83: B-A graf IIR filtrace (notch) vůči původnímu EKG.	97
Obrázek 84: B-A graf IIR filtrace (notch) vůči původnímu EEG.	98
Obrázek 85: B-A graf IIR filtrace (notch) vůči původnímu EMG.....	99
Obrázek 86: B-A graf IIR filtrace (notch) vůči původnímu FK G.....	100
Obrázek 87: B-A graf IIR filtrace (notch) vůči původnímu PPG.	101
Obrázek 88: B-A graf ANC filtrace vůči původnímu EKG.....	102
Obrázek 89: : B-A graf ANC filtrace vůči původnímu EEG.	103
Obrázek 90: : B-A graf ANC filtrace vůči původnímu EMG.	104
Obrázek 91: : B-A graf ANC filtrace vůči původnímu FK G.....	105
Obrázek 92: : B-A graf ANC filtrace vůči původnímu PPG.....	106
Obrázek 93: Porovnání B-A grafů jednotlivých typů vlnek WT vůči původnímu EKG.	107
Obrázek 94: B-A graf WT (Meyerova vlnka) vůči původnímu EEG.	108
Obrázek 95: B-A graf WT (vlnka Db2) vůči původnímu EMG.	109
Obrázek 96: B-A graf WT (vlnka Sym10) vůči původnímu FK G.....	110
Obrázek 97: B-A graf WT (vlnka Sym6) vůči původnímu PPG.	111
Obrázek 98: Syntetické EKG zarušené náhodným šumem.....	112
Obrázek 99: EKG s pohybovými artefakty (4 kanály).....	113
Obrázek 100: Vypočtené nezávislé komponenty pro EKG s pohybovými artefakty.....	114
Obrázek 101: B-A graf ICA metody a původního EKG s pohybovými artefakty.....	115
Obrázek 102: Hlavní komponenty pro EKG s pohybovými artefakty.....	115
Obrázek 103: Ukázka uměle generovaného záznamu abdominálního EKG.	116
Obrázek 104: Plodové EKG získané metodami PCA a ICA.	117
Obrázek 105: B-A graf ICA metody vůči PCA metodě při separaci fEKG.....	117
Obrázek 106: Příklad invazivního a abdominálního EKG.....	118
Obrázek 107: Porovnání metod ICA a PCA s invazivním fEKG.	118
Obrázek 108: B-A graf metody ICA a invazivního fEKG.....	119
Obrázek 109: EKG matky získané metodou PCA a ANC filtrací.	119
Obrázek 110: B-A graf metody PCA vůči ANC filtraci abdominálního EKG.....	120

Seznam tabulek

Tabulka 1: Výsledky FIR filtrace EKG.	20
Tabulka 2: Výsledky filtrace EMG.	28
Tabulka 3: Klasifikace kmitočtů FK G signálu.	29
Tabulka 4: Definice oken FIR filtru.	41
Tabulka 5: Rozsahy pásem použité při analýze EEG.	79
Tabulka 6: Parametry simulovaného EKG pro zpracování v C#.	84
Tabulka 7: Výsledky implementace IIR filtru.	85
Tabulka 8: Výsledky implementace FIR filtru.	85
Tabulka 9: Výsledky implementace klouzavého průměru.	86
Tabulka 10: Parametry generované EKG křivky pro zpracování v Matlabu.	88
Tabulka 11: Parametry generovaného EEG signálu pro zpracování v Matlabu.	89
Tabulka 12: Parametry generovaného EMG signálu pro zpracování v Matlabu.	89
Tabulka 13: Srovnání výsledků FIR filtrace EKG.	92
Tabulka 14: Srovnání výsledků FIR filtrace EEG.	92
Tabulka 15: Srovnání výsledků FIR filtrace EMG.	93
Tabulka 16: Srovnání výsledků FIR filtrace FK G.	94
Tabulka 17: Srovnání výsledků FIR filtrace PPG.	95
Tabulka 18: Srovnání výsledků IIR filtrace EKG.	96
Tabulka 19: Srovnání výsledků IIR filtrace EEG.	97
Tabulka 20: Srovnání výsledků IIR filtrace EMG.	98
Tabulka 21: Srovnání výsledků IIR filtrace FK G.	99
Tabulka 22: Srovnání výsledků IIR filtrace PPG.	100
Tabulka 23: Filtrace ANC signálu EKG.	101
Tabulka 24: Filtrace ANC signálu EEG.	102
Tabulka 25: Filtrace ANC signálu EMG.	103
Tabulka 26: Filtrace ANC signálu FK G.	104
Tabulka 27: Filtrace ANC signálu PPG.	105
Tabulka 28: Vlnková transformace signálu EKG.	106
Tabulka 29: Vlnková transformace signálu EEG.	107
Tabulka 30: Vlnková transformace signálu EMG.	108
Tabulka 31: Vlnková transformace signálu FK G.	109
Tabulka 32: Vlnková transformace signálu PPG.	110
Tabulka 33: Srovnání metod filtrace náhodného šumu v signálu EKG.	112
Tabulka 34: Korelační koeficienty nezávislé komponenty a EKG signálu.	114

Úvod

Cílem diplomové práce je návrh a implementace programu pro modulární zpracování jednorozměrných biologických signálů. Téma práce bylo zadáno ostravskou pobočkou firmy CertiCon, která si slibuje rozvoj v oblasti zpracování signálů. CertiCon je IT firmou, mimo jiné se zabývající právě vývojem ve zpracování biologických dat a zlepšení zdravotní péče využitím nejnovějších informačních technologií.

Práci lze rozdělit do 4 hlavních částí. V první části práce jsou klasifikovány nejpoužívanější biosignály v diagnostice, které jsou využity pro testování navržené aplikace. Jedná se o signál srdeční aktivity EKG, mozkové aktivity EEG, svalové aktivity EMG, pulsové vlny PPG a srdečních ozev FKG. Kapitola pojednává o vzniku jednotlivých signálů, popisuje jejich vlastnosti a způsoby jejich měření. Nedílnou částí je také popis rušení, která se v jednotlivých signálech vyskytují a řešerše metod zpracování, vycházející ze současné literatury a výzkumu.

Součástí druhé části práce je matematický popis jednotlivých metod zpracování signálů, které jsou vybrány na základě řešerše literatury a dále implementovány v programu Matlab. Jedná se o převzorkování signálu, jeho filtrace ve frekvenční i časové oblasti a jejich typy, adaptivní filtrace a další metody zpracování, jako je derivace, vlnková transformace či separace signálů z jejich kombinace.

Třetí část práce popisuje vytvořený program v Matlabu – software pro analýzu jednorozměrných biologických signálů, který umožňuje testování jednotlivých metod zpracování a analýzy signálu. K načtenému signálu lze přidávat některá z nejčastěji vyskytovaných rušení biosignálů. Úpravou signálu pak lze sledovat účinnost jednotlivých metod zpracování a vyhodnotit tak jejich použitelnost v praxi. Součástí třetí kapitoly je také ukázka implementace některých filtračních metod v jazyce C# pomocí .NET Frameworku. Jedná se o čistě testovací program, který má za úkol srovnat zpracování v Matlabu a právě v C#, protože vizí firmy CerciCon je implementace modulárního systému pomocí .NET Frameworku, která by byla velice složitá co do programování komplikovanějších metod analýzy signálu.

V poslední části jsou zpracovány výsledky testování aplikace na syntetických, ale i reálných datech. Je rozdělena na několik podúrovní, kdy každá část je ukázkou zpracování jiného typu artefaktů.

1. Klasifikace měřených signálů

Biologickým signálem je myšlen druh signálu, který má svůj původ v lidském organismu. Může být vyvolán samotnými projevy organismu nebo jej lze vyvolat uměle, kdy je organismus vystaven fyzikálním vlivům z vnějšku. Biologické signály lze rozdělit na několik skupin podle povahy primárních fyzikálních veličin, které jsou měřeny. Mezi nejčastěji využívané biologické signály v rutinní klinické praxi patří signály:

- **bioelektrické**, které mají původ v elektrických dějích, probíhajících na membránách dráždivých buněk,
- **bioakustické**, které poskytují informace o jevu, který generuje snímaný zvuk,
- **biomechanické**, které zahrnují měření polohových výchylek, rychlosti, zrychlení, průtoků či tlaků,
- **biochemické**, které informují o koncentracích látek organismu a jejich pH,
- **tělesná teplota**, kterou nelze zařadit do žádné již zmíněné kategorie.

Mezi další druhy biologických signálů také patří bioimpedanční a biomagnetické signály, které se však pro jejich technickou náročnost měření a malou přínosnost příliš v praxi nepoužívají, [2], [3].

1.1. EKG (elektrokardiogram)


Elektrokardiografie je diagnostická metoda, která umožňuje snímání a záznam elektrické aktivity srdce. Standardně se EKG měří povrchovými elektrodami, přiloženými na končetinách či hrudníku. Elektrickou aktivitu srdce zaručuje převodní srdeční systém¹. Každá část tohoto systému projevuje svou aktivitu specificky i na EKG záznamu. Z EKG křivky lze vyčíst nejen správnou funkci činnosti srdce jejím optickým hodnocením, ale také výpočtem srdeční frekvence, která je důležitým ukazatelem při různých kardiovaskulárních onemocněních, infarktu myokardu nebo poruchách ANS², [1], [2], [3].

1.1.1. Standardy měření EKG


V klinické praxi se používá standardní 12ti svodové EKG se 4 končetinovými a 6 hrudními elektrodami. Pravá noha je využita jako referenční (zemní) elektroda k hrudním svodům, která vzniká propojením končetinových elektrod. Končetinové svody se zpravidla označují jako aVR (pravá ruka), aVL (levá ruka) a aVF (levá noha). Tyto tři končetiny také tvoří svody I, II a III, označované jako Einthovenův trojúhelník (viz Obrázek 1). Středem tohoto trojúhelníku je Wilsonova referenční svorka. Hrudní svody vedené vůči Wilsonově svorce jsou označeny jako V1 – V6 (viz Obrázek 2).

¹ Soubor buněk se schopností autonomně vytvářet vzruchy a ty následně rozvádět po celém srdci.

² Autonomní nervový systém funguje nezávisle na vůli, řídí vnitřní orgány včetně srdce, plic atd.



Obrázek 1: Einthovenův trojúhelník.




Obrázek 2: Rozmístění hrudních elektrod.

Amplituda EKG signálu se pohybuje kolem 1 mV a nejvýznamnější je na frekvencích od 0,05 – 100 Hz. Pro diagnostický účel je doporučena vzorkovací frekvence EKG 500 Hz. Pro dlouhodobější monitorování může být frekvenční pásmo redukováno na 0,5 – 50 Hz, při zátěžových testech až na 30 – 50 Hz s nižší vzorkovací frekvencí 100 Hz. Naopak EKG s vysokým rozlišením vyžaduje širší frekvenční pásmo 0,05 – 500 Hz, [1], [3].

1.1.2. EKG křivka

Na obrázcích níže je znázorněna EKG křivka v časové (viz Obrázek 3) i frekvenční oblasti (viz Obrázek 4), kde jsou vyznačeny její parametry:


- **P vlna** je projevem depolarizace³ síní. Vzhledem k pomalé kontrakci síní a jejich malého rozměru je P vlna pomalá vlna s nízkou amplitudou kolem 0,1 – 0,2 mV, trvá po dobu přibližně 60 – 80 ms a vyskytuje se na frekvencích do 5 Hz s velmi malým výkonem.
- **PQ segmentem** je nazývána izoelektrická část křivky po skončení P vlny, trvající asi 60 – 80 ms. Tato pauza pomáhá dokončení přenosu krve ze síně do komor.
- **QRS komplex** je způsoben rychlou depolarizací komor. Jedná se o prudkou dvoufázovou nebo trojfázovou vlnu o amplitudě 1 mV a s délkou trvání 80 ms. Je nejvýraznější částí EKG křivky, ve frekvenční oblasti nabývá největších hodnot spektrálního výkonu, a to na frekvencích 10 – 20 Hz.
- **ST segment** je projevem fáze plató akčního potenciálu komor. Trvá přibližně 100 – 120 ms.
- **T vlna** pak odráží repolarizaci⁴ srdečních komor. Amplituda se pohybuje v hodnotách 0,1 – 0,3 mV, délka trvání je 120 – 160 ms a frekvence, na kterých se vyskytuje, se pohybuje od 0,5 do 7 Hz.



Obrázek 3: EKG křivka v časové oblasti.

³ Membránové napětí roste směrem k méně negativním, popř. až k pozitivním hodnotám.

⁴ Hodnota membránového napětí se vrací zpět ke klidové hodnotě.



Obrázek 4: Parametry EKG signálu ve frekvenční oblasti.

Jakákoliv odlišnost v obvyklé rytmické aktivitě srdce se nazývá arytmie. Ta může být způsobena nepravidelnou činností SA (sinoatriálního) uzlu, nebo abnormální či přídavnou aktivitou ostatních částí srdce. Mnoho z nich má vlastní rytmicitu a vlastnosti pacemakeru⁵, kromě SA uzlu také např. AV uzel, Purkyňova vlákna nebo síňová i komorová tkáň. Pokud je SA uzel nefunkční nebo je jeho aktivita omezená, některá z těchto součástí přebírá funkci pacemakeru nebo může způsobit ektopické⁶ stahy. V určitých případech může EKG křivka nabývat odlišného tvaru, např. širší QRS komplex značí blok raménka nebo komorovou hypertrofii⁷, zvýšená nebo snížená napěťová úroveň ST segmentu zase srdeční ischemii nebo infarkt myokardu, [1], [3].

1.1.3. Rušení v signálu EKG

Horní hranice frekvenčního pásma EKG 100 Hz je určena výskytem vysokofrekvenčního šumu, který zaujímá značnou část frekvenčního pásma i v oblasti vlastní EKG křivky (cca od 10 Hz). Vyšších hodnot amplitudy však dosahuje právě ve vyšších frekvencích, kde signál značně ovlivňuje a je třeba jej odstranit DP (dolní propust) filtrem. Šum o vysokých frekvencích je způsoben zesilovači, záznamovým systémem či zesílením okolních elektromagnetických signálů napájecími kabely. Specifickým druhem tohoto šumu je rušení z elektrorozvodné sítě 50 Hz, které se ve frekvenčním spektru projevuje vysokým vrcholem jak na této frekvenci, tak i na dalších harmonických. Síťové rušení je nutné odstranit bez jakéhokoli ovlivnění jiných komponent signálu (tedy ideálně odstranit složku pouze o této frekvenci).

Nízkofrekvenčním rušením se pak rozumí primárně pohybové artefakty, způsobené značnými pohyby hrudníku při dýchání nebo kašláním, pohybem končetin nebo špatným kontaktem mezi elektrodou a pokožkou. Respirační složka nízkofrekvenčního rušení se pohybuje v rozmezí od 0,12 do 0,5 Hz a je tudíž lehce odstranitelná HP (horní propust) filtrem. Artefakty rozhraní elektroda–pokožka představují

⁵ Udává rytmus, určuje srdeční frekvenci.

⁶ Stah vznikající mimo srdeční rytmus, v jiném místě srdce než stahy předchozí.

⁷ Tkáň roste vlivem zvětšování objemu jednotlivých buněk.

významný zdroj rušení EKG, který produkuje stejnosměrnou složku o amplitudě 200–300 mV, což je několikanásobek měřeného EKG.

Do zvláštní kategorie lze zařadit artefakty, vznikající vlivem svalové aktivity. Jejich frekvence se pohybují v rozmezí od 5 do 50 Hz, avšak nedosahují příliš vysoké amplitudy, aby signifikantně ovlivňovaly měření, [1], [29].

1.1.4. Metody zpracování EKG

Nejčastější metodou zpracování EKG, která je již dlouhodobě ověřena, je filtrace signálu ve frekvenční oblasti. Typickým představitelem takovéto filtrace je filtr s konečnou impulsní charakteristikou (FIR, Finite Impulse Response). Panda a kol. [12] porovnává výsledky filtrace pomocí obdélníkového, Hanningova, Hammingova a Blackmanova okna. Jsou zde použity filtry řádu 100, propustné pásmo je nastaveno na 3 až 100 Hz. Výsledek prezentuje hodnota poměru užitečného signálu k šumu (Signal to Noise Ratio, SNR) v jednotkách dB (viz Tabulka 1), vypočítána dle vztahu (1.1).

$$\text{SNR}_{\text{dB}} = 10 \cdot \log \frac{P_s}{P_n}, \quad (1.1)$$


kde P_s je výkon užitečného signálu a P_n je výkon rušení, přidaného k signálu.

Tabulka 1: Výsledky FIR filtrace EKG.

Typ okna	SNR (dB)
Obdélníkové	20,31
Hanning	17,65
Hamming	17,9
Blackman	18,01

Jagtap a kol. [13] používá filtraci Butterworthovým filtrem s nekonečnou impulsní charakteristikou (IIR, Infinite Impulse Response), kdy je použita DP řádu 5 (mezní frekvence 100 Hz), HP řádu 3 (mezní frekvence 0,5 Hz) a notch filtr řádu 4 (mezní frekvence 50 Hz). Všechny tyto filtry byly vyhodnoceny jako stabilní. Dále byla otestována filtrace v případě kaskádního zapojení filtrů, která se prokázala jako kvalitnější.

Mezi další způsoby filtrace EKG se řadí vlnková transformace (WT, Wavelet Transform) nebo klouzavý průměr, kterými se zabývá [11]. V případě WT lze použít vlnu DB4 (Daubechies, viz Obrázek 5), která dokáže ze signálu odstranit jak všechny vysoké frekvence, tak i síťové rušení. Klouzavý průměr lze pak využít pro zvýraznění pouze QRS komplexů, např. při použití pro výpočet tepové frekvence z detekce R vlny.



Obrázek 5: Vlna DB4.

1.2. EEG (elektroencefalogram)


Elektroencefalografie je diagnostická metoda, umožňující snímání a záznam elektrické aktivity mozku. Měření EEG lze rozdělit podle místa snímání na invazivní (podpovrchovými jehlovými elektrodami) a neinvazivní (povrchovými elektrodami). Je měřena buď spontánní činnost mozku anebo reakce mozku na vnější podněty – vyšetření tzv. evokovanými potenciály (EP, rozlišujeme somatosenzorické, sluchové a zrakové). Indikací k tomuto vyšetření jsou různé neurologické a psychické poruchy či epileptické záchvaty. Používá se také ke sledování spánkové aktivity v jednotlivých fázích či ke spolupráci mozku s počítačem aj., [1], [3].

1.2.1. Standardy měření EEG

Při klinickém záznamu EEG se používá mezinárodní systém rozmístění povrchových elektrod „10 – 20“ (viz Obrázek 6). Název je odvozen ze vzdáleností úseků mezi elektrodami – 10 nebo 20 %. Rozložení elektrod je symetrické, krajní body vymezují nasion⁸, inion⁹ a ušní boltce. Pro správné umístění dle tohoto systému jsou používány sítky nebo čepice. Celkem je použito 21 elektrod, z toho 19 se nachází na povrchu lebky a 2 jsou umístěny na každém z ušních lalůčků (referenční elektrody). Při měření se využívá záznamu z 8 až ze všech 21 kanálů. Ambulantně se délka vyšetření pohybuje kolem 20 minut, avšak při sledování spánkové aktivity či diagnóze epilepsií může měření trvat několik hodin i dní.

⁸ Místo prohlubně u kořene nosu.

⁹ Výstupek uprostřed kosti týlní.



Obrázek 6: Rozmístění EEG elektrod dle systému 10–20 při pohledu na lebku shora.

Amplituda signálu je velmi malá, dosahuje hodnot kolem $100 \mu\text{V}$. Běžná vzorkovací frekvence pro EEG je 256 Hz, u EP se používá až 6 kHz. Frekvenční rozsah EEG signálu je až 80 Hz, avšak k rutinnímu diagnostickému vyšetření se používá pásmo 0,5 – 30 Hz, [1], [3].


1.2.2. EEG záznam

Pásmo EEG signálu je rozděleno do jednotlivých frekvenčních oblastí (viz Obrázek 7 a Obrázek 8):


- **Delta** rytmus s frekvencí $0,5 \leq f < 4 \text{ Hz}$ je příznakem fází hlubšího spánku.
- **Théta** rytmus s frekvencí $4 \leq f < 8 \text{ Hz}$ se vyskytuje v počátečních fázích spánku.
- **Alfa** rytmus s frekvencí $8 \leq f \leq 13 \text{ Hz}$ je hlavním projevem klidové aktivity mozku. Nejvyšších hodnot dosahuje při tzv. relaxované bdělosti¹⁰.
- **Beta** rytmus s frekvencí $13 < f < 30 \text{ Hz}$ se vyskytuje u nervózních či znepokojených subjektů. Amplituda nepřesahuje $20 \mu\text{V}$, jedná se o aktivitu v pozadí ostatních rytmů.

V literatuře je také zmiňován tzv. gama rytmus s frekvencí 30 – 80 Hz, který se považuje za důsledek odezvy na různé druhy senzorických podnětů. Snížení nebo absence rytmu, který lze očekávat v jistém stavu měřeného subjektu, je považováno za abnormalitu. Např. místní poranění mozku nebo nádor vedou k abnormálnímu zpomalení vln v souvisejících oblastech, hroty a ostré vlny zase indikují přítomnost epileptických ložisek, [1], [2], [3].

¹⁰ Měřený subjekt klidně leží se zavřenýma očima.



Obrázek 7: Příklad EEG signálu a jeho rozložení na jednotlivé rytmy.



Obrázek 8: Rozdělení pásem EEG ve frekvenční oblasti.

1.2.3. Rušení v EEG záznamu

Měření EEG je podobně jako EKG ovlivňováno okolními rušivými signály ze záznamové jednotky, zesilovačů a kabelů, nebo pohybu dalších osob kolem pacienta. Oproti EKG však EEG záznam tímto šumem trpí více, z důvodu jeho velmi malých amplitud. Pokud tedy není rušení dostatečně potlačeno, může dojít k naprostému útlumu EEG signálu, které znemožní jeho záznam. V signále se také vyskytuje rušení rozvodné sítě 50 Hz, které se nejvýrazněji vyskytuje mezi elektrodami a zemí zesilovače.

Nejběžnějším fyziologickým rušením EEG signálu jsou myopotenciály, nejčastěji způsobeny svaly v oblasti spánku a čela. Tyto potenciály však trvají krátkou dobu oproti potenciálům generovaným mozkovými buňkami a z hlediska jejich tvaru a frekvence mohou být snadno v EEG záznamu identifikovány. Existují některé zvláštní vzory těchto artefaktů, které mohou nastat u konkrétních pohybových poruch (např. rytmické sinusoidní artefakty o frekvenci 4–6 Hz při Parkinsonově chorobě).

Mezi nízkofrekvenční rušení EEG signálu se dále řadí pohybové artefakty, hlavně artefakty způsobené pohybem očí a jazyka. Pohyb jazyka má za následek široké pole potenciálu (většinou v pásmu delta), které klesá z čelních na okcipitální oblasti, avšak nedosahuje tak významných amplitud jako artefakty pohybu očí. Oční pohyby jsou zřetelné na jakémkoli záznamu EEG, užitečné jsou pak při identifikaci spánkových stádií. Pohybem oční bulvy kolem její osy se generuje střídavý proud s velkou amplitudou, který je zřetelný na elektrodách blízko očí. Současně s ním jsou zdrojem artefaktu potenciály svalů očního důlku. Ve většině měřených kanálů se tento artefakt projevuje výrazným poklesem EEG signálu. Pomalé či strmé vlny v záznamu EEG jsou důsledkem dýchání, vznikají synchronně s nádechem či výdechem a vyskytují se v kanálech elektrod, na kterých pacient leží. Pomalé trendy v signálu mohou také vznikat vlivem pocení, které se projevuje jako kolísání signálu na frekvenci 0,2 – 0,5 Hz.

EEG záznam může interferovat s EKG signálem. Ten je však pro svou rytmičnost a pravidelnost lehce zjištělný. Velikost napěťové úrovně tohoto artefaktu se u jednotlivých měření liší, proto se běžně využívá možnosti snímání EKG současně s EEG signálem, kdy je možné vliv EKG pozorovat, [30].

1.2.4. Metody zpracování EEG

V literatuře jsou nejčastěji zmiňovány dvě metody předzpracování EEG – WT a metoda analýzy nezávislých komponent (Independent Component Analysis, ICA), nebo také jejich kombinace. V případě WT jsou nejčastěji testovány vlnky Daubechies, Mexická a Coifletova. Yavuz a kol. [19] dosáhli nejvyšší přesnosti odstranění artefaktů ze signálu s použitím Mexické vlnky (až 94,09 %). Zjistili však, že tato metoda závisí také na čichové schopnosti testovaného subjektu, jelikož subjekty byly vystaveny různým pachovým vjemům (použita byla vůně lotosového květu a sýra). Nejnižších hodnot přesnosti dosahovala u subjektu, který měl nejmenší čichovou schopnost vůči zbytku.

Samostatnou metodu ICA použil Corradino a kol. [22], kdy ICA byla použita k detekci artefaktů, které byly nadále odstraněny dalším algoritmem (Ordinary least square, OLS). Matice nezávislých komponent je dále vyčištěna notch filtrem, protože existuje předpoklad jisté frekvence zjištěného artefaktu. Postup se ukázal jako efektivní, avšak není vhodný pro online zpracování signálu z důvodu časové náročnosti ICA algoritmu. Torse a kol. [23] srovnává více metod předzpracování EEG, a to fastICA, runICA, metodu analýzy hlavních komponent (Principal Component Analysis, PCA) a adaptivní filtraci s a bez referenčního signálu, přičemž zkoumá jejich vliv na artefakty EOG (elektrookulografie) a epileptické části záznamu. Metody jsou srovnány ze dvou aspektů; střední kvadratické chyby a výpočetních časů. Adaptivní filtrace se významně liší od ostatních metod svou krátkou výpočetní dobou, avšak na úkor přesnosti, která dosahuje mnohem vyšších hodnot právě u ostatních metod ICA (nejpřesnější) a PCA (nejrychlejší, v přesnosti se umístila za ICA).

Véléz-Pérez a kol. [20] spolu s Romo-Vazquezem a kol. [21] se zabývají kombinací metody ICA, konkrétně algoritmu separace slepých zdrojů (Blind Source Separation, BSS), a WT. Obě studie dochází

k závěru uspokojující redukce šumu a artefaktů, jako je mrkání. Véléz-Pérez a kol. [20] pak poukazuje na nedostatečné odstranění vysokých frekvencí, ale došlo k jejich výraznému potlačení, které napomáhá kvalitnějšímu optickému hodnocení křivky. Pro tuto studii, zabývající se lateralizací¹¹ EEG, má výsledek předzpracování signifikantní význam, jelikož vypočtený index se zvyšuje u hemisféry obsahující epileptická ložiska, zatímco u opačné hemisféry je nízký. Romo-Vazquez a kol. [21] za nejvhodnější metodu k odstranění šumu i artefaktů považuje SOBI-RO algoritmus ICA metody a SURE algoritmus WT, přičemž WT používá až po použití ICA.

1.3. EMG (elektromyogram)

Elektromyografie je diagnostická metoda, umožňující snímání bioelektrických signálů, vznikajících činností kosterního svalstva. Často je prováděna při současné stimulaci příslušných motorických a periferních nervů. Snímání lze provádět invazivně i povrchově, na úrovni jediného svalového vlákna, jedné motorické jednotky nebo i celého svalu. Zpracováním informace z EMG lze diagnostikovat svalové a neuromuskulární poruchy, analyzovat chůzi či použít EMG k rehabilitaci nebo řízení končetinové protézy, [1], [3].

1.3.1. Měření EMG

Při vyšetření se mohou používat jak monopolárně, tak bipolárně zapojené elektrody a v některých případech se kombinuje použití intramuskulárních a povrchových elektrod. Pro snímání z povrchu se používají tzv. multielektrody, kdy jsou elektrody umístěny v prohlubních na silikonové podložce buď v řadě (stripy) nebo v matici (gridy). Pro snížení rušení souhlasným napětím lze využít napájení pravou nohou, podobně jako u EKG, kdy zemnicí elektrodu umísťujeme dostatečně daleko od místa snímání.

Frekvenční rozsah EMG se pohybuje v pásmu od 0,01 Hz do 10 kHz v závislosti na druhu snímání (invazivní či povrchové). Za nejvýznamnější se ale považuje rozsah od 50 do 150 Hz, [1], [3].

1.1.1. EMG záznam

Záznam EMG lze rozdělit na dvě hlavní kategorie – akční potenciál motorické jednotky (Motor Unit Action Potential, MUAP) a sumární akční potenciály svalu (Compound Muscle Action Potential, CMAP).


MUAP

Svaly jsou složeny z motorických jednotek, což je nejmenší možná část svalu, kterou lze aktivovat vůlí. Součet akčních potenciálů příslušných svalových vláken lze měřit invazivně jehlovými elektrodami, umístěnými do svalu v oblasti zájmu. Takto získaný signál je superpozicí jednotlivých MUAP, je proto nutné tento signál dále dekomponovat na příspěvky jednotlivých motorických jednotek.

Normální MUAP (viz Obrázek 9) bývají dvoufázové nebo třífázové, trvají kolem 3 – 15 ms a dosahují amplitudy 100 – 300 μ V. Vyskytují se s opakováním 6 – 30 MUAP za sekundu. Tvar zaznamenaných MUAP závisí na typu použité jehlové elektrody, jejím umístění vzhledem k motorické jednotce a projevu elektrické aktivity na elektrodách. Dále se tvar liší v případě některé z nemocí, např.

¹¹ Hledání hemisféry, která je zdrojem epileptické aktivity.


neuropatie nebo myopatie. Neuropatie způsobuje pomalé vedení vzruchu anebo nesynchronizovanou aktivaci svalových vláken v rámci jedné motorické jednotky. MUAP má v tomto případě vyšší amplitudu. Myopatie se projevuje ztrátou svalových vláken, kdy neurony jsou nefunkční. Dochází pak k roztržení MUAP kvůli asynchronní aktivaci, které vede k několikafázovým MUAP, [1], [3].



Obrázek 9: Příklady akčních potenciálů různých motorických jednotek (MUAP).


CMAP

Další možností měření EMG je záznam aktivity celého svalu (viz Obrázek 10), která sestává ze součtu jednotlivých MUAP. Měří se povrchovými elektrodami a její analýza je mnohem složitější. K analýze se využívá frekvenční pásmo od 10 Hz do 1 kHz. Vzorkovací frekvence se používá 2 kHz. Signál dosahuje amplitudy až 10 mV. Při viditelně snížené amplitudě signálu je pravděpodobnost nemoci primárně svalstva. Pokud amplituda klesá postupně, jedná se o poruchu přenosu na nervosvalové ploténce. Při demyelinizaci¹² nervů dochází ke zpoždění kontrakce svalových vláken při normální amplitudě odezev.



Obrázek 10: Příklad EMG měřeného povrchově.

¹²Ztráta myelinu z nervových vláken axonů, která způsobuje poškození nervů i mozku a míchy – typickou chorobou s tímto příznakem je roztroušená skleróza.



Obrázek 11: Příklad frekvenčního spektra povrchově měřeného EMG.

Při měření EMG je vyhodnocována tzv. maximální volní kontrakce svalu. Požadované síly kontrakce je dosaženo postupnou aktivací motorických jednotek. Počet aktivovaných jednotek, potřebný k této kontrakci, se liší v závislosti na velikosti svalů. Nejprve jsou vždy aktivovány motorické jednotky, které inervují menší počet svalových vláken, se zvyšující se potřebou kontrakce se pak zapojují jednotky inervující větší počet vláken. Tím je umožněno pomalé stupňování kontrakce. Sval nikdy nemůže dosáhnout konstantní síly kontrakce, vzhledem k určitým výkyvům času šíření akčního potenciálu motorickou jednotkou a k různorodosti reakce svalového vlákna na podráždění. Byly zjištěny oscilace kontrakce o frekvenci 1 – 2 Hz, [1], [3].

1.1.2. Rušení EMG signálu

Významným rušením povrchově měřeného EMG signálu jsou pohybové artefakty, které se velmi těžko odstraňují. Jsou způsobeny pohybem senzoru vůči pokožce v oblasti zájmu. Vzniká buď přímým tlakem na senzor, rychlým pohybem části těla, kde je senzor připevněn, nebo změnami v rovnováze rozhraní elektroda–pokožka vlivem objemových změn způsobených svalovou kontrakcí. Tyto artefakty jsou pak problémem při měření dynamických činností. Pohybové artefakty se vyznačují vrcholem s vysokou amplitudou oproti EMG signálu, vyskytují se však na nízkých frekvencích a lze je tedy odstranit HP filtrem (s mezní frekvencí např. 20 Hz), který neovlivní sledované frekvenční pásmo EMG signálu.

Dalším typem artefaktu je kontaminace signálu EMG signálem vedlejšího svalu, který není v oblasti zájmu. Data jsou pak zkreslena v amplitudě i čase trvání EMG signálu. Tento artefakt je možné potlačit přidáním referenčních elektrod, díky nimž lze porovnat amplitudy generovaných myopotenciálů a na jejich základě vyhodnotit průběh signálu v oblasti zájmu.

Odpojením senzoru nebo nadměrnou amplitudou signálu může dojít k saturaci signálu, která se projevuje zkreslením vysokých amplitud. Pro její předejití by měl být zkontrolován kontakt elektrody s pokožkou, sníženo zesílení zesilovače nebo přemístěna elektroda na jiné místo svalu, kde je amplituda redukována.

Podobně jako v případě EEG záznamu, i EMG záznam je významně ovlivňován EKG signálem. Toto rušení se nejvíce projevuje u měření na svalech horní části těla. Problémem je vysoká amplituda EKG

signálu vůči EMG a překrývání jejich frekvenčních spekter, tudíž není možná běžná filtrace ve frekvenční oblasti a je třeba pokročilejších metod k odstranění tohoto artefaktu. Pokud je to možné, vhodnější je měřit EMG signál co nejdál od srdce.

Mezi technické artefakty pak patří síťové rušení 50 Hz a elektromagnetické rušení ostatních přítomných přístrojů a komponentů záznamového systému. Pro potlačení vysokofrekvenčního rušení lze použít DP filtr s mezní frekvencí vyšší než je frekvenční rozsah sledovaného EMG signálu, [31], [32], [33].

1.1.3. Metody zpracování EMG

Nejvýznamnějším problémem při zpracování EMG je jeho nestacionarita, která komplikuje použití klasických metod filtrace ve frekvenční oblasti. Filtrací síťového rušení se zabývá Soedirdjo a kol. [9], kde jsou srovnány výsledky filtrace povrchového EMG notch filtrem, spektrální interpolací, Keshtkaranovým a Yangovým adaptivním filtrem a adaptivním filtrem s fázovým závěsem. Pro měření byly použity třísekundové záznamy 16ti kanálového EMG, kdy byly rozeznávány první 3 harmonické složky jedné amplitudy. Výsledky jsou interpretovány hodnotou SNR (viz Tabulka 2) a korelačními koeficienty.

Tabulka 2: Výsledky filtrace EMG[9].

	SNR [dB]
Filtr s fázovým závěsem	25,96
Notch filtr	12,44
Adaptivní filtr	9,33
Spektrální interpolace	6,19

Reaz a kol. [10] se zabývá metodami dekompozice EMG jedné motorické jednotky z povrchového EMG a analýzy EMG. Pro dekompozici se může využít segmentace, WT, která je vhodná i při zarušení signálu nízkofrekvenčním driftem či vysokofrekvenčním šumem, dále PCA nebo shlukování. WT lze využít také pro analýzu, kdy se používá vlna druhé derivace Gaussovy křivky (tzv. Mexický klobouk), která se podobá EMG jedné motorické jednotky. Klasické frekvenční metody – klasická či krátká Fourierova transformace (FFT, Fast Fourier Transform) se pro analýzu EMG nepoužívají, jelikož jsou vhodné pouze pro stacionární signály. Namísto nich lze využít časově-frekvenční analýzu ke sledování nestacionarit v měření (např. únava svalů), autoregresních modelů či umělé inteligence (neuronové sítě).

1.2. FKG (fonokardiogram)

Fonokardiografie je diagnostická metoda grafické registrace ozev, které provázejí mechanické kmity vznikající v srdci a cévách. Nemoci kardiovaskulárního systému se projevují změnami v srdečních ozvách, přidanými ozvami nebo šelesty. Tyto příznaky pomáhají k jejich diagnostice, [1], [3].

1.2.1. Měření FKG

Měření FKG vyžaduje převodník vibrací nebo zvuku na elektrický signál; mikrofony, tlakové převodníky nebo akcelerometry mohou být pro tento účel umístěny na povrchu hrudníku. Běžně se k nahrávání FKG používají piezoelektrické senzory, které jsou velmi citlivé na pohyb po povrchu pokožky. Frekvenční rozsah senzoru může být 0,05 – 1000 Hz. Fonokardiografický signál lze měřit v různých kmitočtových pásmech (viz Tabulka 3), [1], [3].


Tabulka 3: Klasifikace kmitočtů FKG signálu.

Označení pásma	Horní mezní kmitočet [Hz]
Nízké 1	35
Střední 1	70
Střední 2	140
Vysoké 1	250
Vysoké 2	400

1.2.2. FKG záznam

Srdeční ozvy nejsou způsobeny pohybem chlopní samotných, jak bylo uváděno dříve, ale vibracemi celého kardiovaskulárního systému spouštěného tlakovými gradienty. Normální srdeční cyklus obsahuje dvě hlavní ozvy, avšak celkem jsou rozlišovány čtyři základní ozvy: první systolická (je delší a hlubší, její počátek souhlasí s vrcholem R vlny), druhá diastolická, třetí protodiastolická a čtvrtá presystolická. Průběh FKG signálu a jeho souvislost s křivkou EKG je vysvětlen níže (viz Obrázek 12):

- **První ozva (S1)** vzniká nejprve při první kontrakci myokardu, kdy dochází k přenosu krve z komor do síní a uzavření mitrální a trikuspidální chlopně. Druhá část S1 vzniká v důsledku prudkého tlaku při uzavření těchto chlopní, kdy se přenos krve prudce zpomaluje. Třetí část S1 může být způsobena oscilacemi krve mezi kořenem aorty a stěnami komor. Následuje čtvrtá komponenta S1 jako výsledek vibrací způsobených turbulencí rychle plynoucí krve vzestupnou aortou a plicní tepnou. Vznikají vibrace o frekvenci od 25 do 45 Hz.
- **Druhá ozva (S2)** vzniká jako výsledek uzavření semilunárních chlopní. Skládá se ze dvou částí, z nichž každá je důsledkem uzavření jedné chlopně (první v aortě, druhá v plicnici). Mezi těmito komponenty je krátká pauza několika ms, která se u normálních subjektů prodlužuje při nádechu. Vibrace S2 mají frekvenci kolem 50 Hz.
- **Třetí ozva** může být v některých případech zaznamenána při plnění komor krví. Protože jsou ale komory relaxované, vibrace se vyznačují velmi nízkou frekvencí.
- **Čtvrtá ozva** pak může být slyšitelná při kontrakci síní, převádějící krev do komor.



Obrázek 12: Průběh FKG signálu a jeho souvislost s EKG křivkou.

Šelesty, způsobené určitými kardiovaskulárními poruchami, mohou narušovat intervaly mezi S1 a S2/ S2 a S1, kde se v běžných případech signál nevyskytuje. Jedná se o zvuky podobné šumu o frekvenci nad 600 Hz, které jsou výraznější při zvýšení rychlosti krve při průtoku přes nepravidelnosti, jako je překážka či zúžení. Typicky k turbulenci krve dochází při stenóze¹³ nebo nedomykavosti¹⁴ chlopní. Systolické šelesty mohou vznikat vlivem poškození komorového septa, stenózy aorty nebo plicnice, mitrální nebo triskuspidální nedostatečnosti. Diastolické šelesty jsou důsledkem nedostatečnosti aorty, plicnice nebo mitrální či trikuspidální stenózy. Mnoho vlastností srdečních ozvů a šelestů, jako je intenzita, frekvence nebo průběh v čase, je ovlivněno spoustou fyzických a fyziologických faktorů, [1], [3].

1.2.3. Rušení v FKG signálu

Za významné typy rušení FKG signálu jsou považovány zvuky vznikající vlivem respirace, pohybu pacienta, pohybu senzoru, akustického tlumení kostí a jiných tkání a šumem okolního prostředí. Vzhledem k překrývání frekvenčního spektra a jejich podobnosti s vlastním FKG signálem jsou nejméně žádané artefakty dýchání a pohybu senzoru po pokožce, [34]. Bylo vyzkoušeno mnoho metod, jak tyto artefakty potlačit, popř. jak ze zarušeného signálu naopak získat pouze diagnosticky přínosný FKG signál, z nichž některé jsou přiblíženy v další kapitole.

1.2.4. Metody zpracování FKG

Pro zpracování FKG signálu je v literatuře probíráno mnoho metod včetně různých jejich modifikací. Jain a kol. [14] k analýze FKG používá diskrétní WT (DWT), která má schopnost potlačit šum jak v pásmu, tak i mimo pásmo. Problematika metody však spočívá v odhadu prahové hodnoty – vysoký práh může ovlivnit přímo komponenty signálu, zatímco nízký práh dostatečně nepotlačuje šum. Dále je aplikována prahová funkce, díky které jsou získány koeficienty WT – je zde použita měkká prahová funkce (DWT-B), která redukuje vliv přechodů v signálu, tvrdá prahová funkce (DWT-A), která poskytuje vyšší SNR, „mid“ funkce, která ponechává velké koeficienty, odstraňuje malé a středně velké lineárně přizpůsobuje zvolenému prahu, a „nelineární mid“ funkce, která pracuje podobně s tím rozdílem, že koeficienty přiřazuje nelineárně. Signál je dekomponován na přibližné (DP) a podrobné

¹³ Chlopeň se nedostatečně otevírá v důsledku ztuhlosti např. úbytkem vápníku a staví tak překážku vypuzované krvi.

¹⁴ Chlopeň není dostatečně uzavřena a způsobí pak zpětné unikání krve úzkým otvorem.

(HP) koeficienty, vzniká tak 5 úrovní signálu, z nichž článek se zabývá posledními dvěma (podstatná část signálu leží ve frekvencích 30–100 Hz). Práh je stanoven výpočtem horního kvartilu signálu jako:

$$T = \begin{cases} Med_{75} \cdots Med_{75} < mean \\ Med_{75} + 2(Med_{75} - mean) \cdots otherwise \end{cases} \quad (1.2)$$

Metoda je aplikována pro odstranění Gaussova, růžového a červeného šumu. Nejvyššího SNR dosáhla nelineární mid funkce, méně úspěšná byla metoda mid funkce a pak se postupně umístily DWT-A a DWT-B. V případě použití reálného zašuměného signálu potlačily nově použité metody šum mnohem výrazněji.

Jako dostatečně přesná byla také označena metoda autokorelační funkce, kterou popisuje Sabir a kol. [15]. Byly zde použity 3 různé vzorkovací frekvence a 3 různá okna pro detekci alespoň dvou cyklů S1, S2. Pro průběžný odhad energie signálu byl využit Teagerův operátor ($\phi[x[n]] = x^2[n] - x[n-1]x[n+1]$). V autokorelační funkci signálu jsou pak vyhledávána lokální maxima. První maximum značí vzdálenost S1 k S2, druhé vzdálenost S2 k dalšímu S1 a třetí pak vzdálenost od S1 k dalšímu S1 (srdeční frekvence).

Yang a kol. [16] používá k analýze FKG metodu ICA. Každý srdeční cyklus je určen jako jeden element výsledného vektoru (vznikají tak 4 elementy). Studie poukazuje na viditelný rozdíl v ICA mezi normálními subjekty a subjekty s poruchou síňového septa.

Další možností analýzy FKG je převod signálu na dvourozměrný [17], kdy jsou po nutném předzpracování obrazu (stupně šedi, normalizace pozadí, binarizace, vyhlazení) a normalizaci amplitudy nalezeny inflexní body, podle kterých je vytvořeno 14 cyklů signálu a vypočten sklon signálu v jednotlivých souřadnicích. Pro interpretaci výsledků je vypočten parametr stupeň jistoty a Euklidovská vzdálenost. Dále je použita WT, kdy jsou horizontální a vertikální koeficienty zkombinovány do jednorozměrného vektorového objektu. Ve srovnání s analýzou jednorozměrného FKG je analýza touto metodou relativně vysoká (míra rozpoznání dosahuje 94 %), navíc je tato analýza několikrát násobně výpočetně rychlejší.

Další metody srovnává Chakrabarti a kol. [18]. Je použita metoda FFT (100% rozpoznání S1, 97% rozpoznání S2), kde však může dojít ke ztrátě patologických projevů (analýza vylučuje počáteční část systoly), fuzzy logika (přesnost pouze 80 %), metoda výpočtu obálky a Hilbertovy transformace (přesnost 91 %) a empirická modální dekompozice (EMD) s předzpracováním WT (99,74% přesnost). WT může být nedostatečná při nižších frekvencích signálu, jelikož její koeficienty se pohybují ve frekvencích vyšších.

1.3. PPG (fotopletysmograf)


Pletysmografie je vyšetřovací metoda, která slouží k hodnocení jakosti prokrvení tkání a poskytuje informaci o činnosti a reaktivitě cév. Rozvoj metody způsobil objev fotopletysmografu, který umožnil provádět snímání jednoduchým způsobem v klinickém prostředí. Tento PPG umožňuje získat záznam pulsových vln během srdeční akce pomocí snímače nejčastěji umístěného na konečku prstu. Variabilita tvaru tohoto záznamu je však velmi široká, proto nebyla dosud přijata hranice mezi fyziologickým a patologickým průběhem křivky. Nejčastěji je PPG využíváno k měření tepové frekvence, [3].

1.3.1. Měření PPG

K měření PPG je využíván buď snímač transmisní, nebo reflexní. Jeho principem je světlo procházející přes krevní řečiště. Při změnách tlaku krve se mění objem kapilár a dochází ke změnám absorpce odrazu a rozptylu světla. Používá se optoelektronický snímač se zdrojem světla pracujícího v infračervené oblasti (např. LED). Jako detektor se používá fototranzistor nebo fotodiody. Snímač PPG je velice citlivý na pohyb, jehož artefakty se ze signálu velmi špatně odstraňují, [3].

1.3.2. Pulsová vlna

Na pulsové vlně rozlišujeme vzestupné a sestupné raménko (představuje pohyb cévní stěny po přechodu vlny). Sestupná část je přerušena hlubokým zářezem, vznikajícím v důsledku uzavření semilunárních chlopní. Periferní pulsová vlna (viz Obrázek 13), měřená prstovým PPG, sestává z přímého vzestupného raménka, zaobleného zářezu a dikrotické vlny. Na dikrotickou vlnu mohou navazovat vlnky ležící ve vzdálené části sestupného raménka, za jejichž původ jsou považovány vibrace na konce řečiště. Tvar periferní pulsové vlny se liší při hrubých změnách srdeční hemodynamiky, u chlopňových vad a při změnách celkového tlaku (např. rychlý spád raménka signalizuje aortální nedostatečnost), [3].



Obrázek 13: Průběh periferní pulsové vlny.

1.3.3. Rušení v PPG signálu

Vlivem napájecích kabelů, přístrojových zesilovačů a záznamového zařízení, které zvyšuje elektromagnetické rušení, vzniká vysokofrekvenční šum. Na frekvenci 50 Hz a jejích dalších harmonických se vyskytuje artefakt síťového brumu. Vzhledem k velmi nízkému výkonu PPG signálu na frekvencích vyšších než 5 Hz není problém takto zanesené artefakty odstranit DP filtrem.

Pohybové artefakty v případě měření PPG vznikají převážně vlivem slabého kontaktu senzoru s pokožkou, avšak kolísání linie mohou způsobit např. i změny teploty. Vzhledem k velké citlivosti optického senzoru na tyto pohybové artefakty a překrývajícím se frekvenčním spektrům nízkofrekvenčního rušení a PPG signálu je třeba použít pokročilejší metody předzpracování, [35].

1.3.4. Metody zpracování PPG

Mnoho studií se zabývá efektivním odstraněním pohybových artefaktů, vnikajících pohybem senzoru po pokožce, či alespoň jejich částečnou eliminací, aby bylo možno naměřit i dlouhodobější záznamy. Například Kim a kol. [24] se zabývá separací pohybových artefaktů metodou ICA a PICA (ICA s předzpracováním). Předzpracování sestává z detekce periody signálu (např. autokorelační funkce), prokládacího bloku a filtru typu DP (klouzavý průměr). Takto připravený signál je prohnán reverzním blokem k prokládacímu a dále může proběhnout vlastní ICA. Ze závislosti střední kvadratické chyby (Mean Squared Error, MSE) a SNR je patrné, že s klesajícím SNR MSE roste, avšak u zpracování pomocí PICA metod je MSE mnohem menší, hlavně právě u menších hodnot SNR.

Pang a kol. [25] odstraňuje pohybové artefakty pomocí metody EMD, která je běžně pro tento účel využívána, doplněná o výpočet řad rozptylových charakteristik (výpočet rozptylu mezi každým maximem a následujícími 7mi dalšími a stejným způsobem mezi minimy). Dosažená chyba je zde 1,03 %, u jiných metod, jako je samostatná EMD, chyba dosahuje hodnot kolem 3 %.

Wu a kol. [26] používá metodu EMD s přidáním bílého šumu. Zabývá se dlouhodobým monitorováním, kdy by samotná EMD nebyla pro eliminaci pohybových artefaktů dostatečná. Madhav a kol. [27] pomocí robustní metody ICA oddělují dechovou křivku z PPG signálu, čímž dochází i k separaci pohybových artefaktů. Studie došla k vysoké korelaci s originální dechovou křivkou.

2. Metody zpracování signálů


Většina biologických signálů se jeví jako křehké signály, v jejichž prostředí se vyskytuje mnoho dalších signálů různého původu. Každý takovýto signál, který není v centru našeho zájmu, může být nazván rušením, artefaktem či souhrnně šumem. Zdroje šumu mohou být fyziologické (vzájemný vliv různých orgánů, biologické rytmy, pohyb rozhraní elektroda–elektrolyt), použité zařízení (rušení elektrorozvodnou sítí, vlastní šum elektronických prvků a obvodů) či prostředí, ve kterém je měření provedeno. Je proto třeba před samotnou analýzou signálu provést předzpracování, které tento nežádoucí šum odstraní nebo alespoň potlačí a lze pak ze signálu získat hodnotnější informaci nebo také předvídat vývoj hodnot signálu a tím předejít chování jeho zdroje, [1], [2], [3]. Některé základní metody předzpracování biologických signálů, vybrané převážně na základě rešerše aktuální literatury, jsou blíže popsány dále.

2.1. Převzorkování signálu

Převzorkování signálu se využívá v případech, kdy použitá vzorkovací frekvence signálu není dostatečně vysoká pro některé specifické typy analýzy (např. u EKG délka trvání RR či ST intervalu, šířka T nebo P vlny apod.), nebo naopak kdy není třeba příliš vysoké rozlišovací schopnosti při analýze a vzorkovací frekvence je tak snížena, aby umožnila rychlejší, i když méně přesné zpracování signálu. Nejčastěji se využívá kubické interpolace a spline interpolace, která je přesnější, avšak výpočetně pomalejší. Dalšími metodami je lineární interpolace a interpolace nejbližším sousedem, které se však ve zpracování biologických signálů příliš nevyužívají z důvodu menší přesnosti. Pro převzorkování může být využita také metoda frekvenční, která spočívá v upravení vzorkovací frekvence ve frekvenční oblasti signálu a ve zpětném převedení do oblasti časové. Srikanth a kol. [8] jednotlivé typy převzorkování demonstruje na signálu EKG a porovnává nejrozšířenější metody převzorkování, jejich výhody a nevýhody. Některé základní metody jsou blíže popsány níže.

Interpolace nejbližším sousedem

Interpolace nejbližším sousedem je nejjednodušším typem interpolace. Princip metody spočívá v proložení intervalu mezi interpolovanými body po částech spojitou konstantní funkcí, tj. v okolí každého bodu jsou přidány body o hodnotě tohoto bodu (viz Obrázek 14). Nevýhodou této metody je zkreslení v časové oblasti, zejména v místech vrcholů a zákmitů.




Obrázek 14: Příklad interpolace nejblížeším souseďem.

Lineární interpolace

Lineární interpolace (viz Obrázek 15) je založena na prokládání interpolovaných bodů (x_a, y_a) a (x_b, y_b) body (x, y) tvořících lineární funkci dle vztahu (2.1).

$$y = y_a + (y_b - y_a) \frac{x - x_a}{x_b - x_a}. \quad (2.1)$$


Nevýhodou lineární interpolace je nedostatečná přesnost na nízkých frekvencích.



Obrázek 15: Příklad lineární interpolace.

Kubická interpolace

Kubická interpolace (viz Obrázek 16) je typem interpolace křivek po obloucích, tj. každý úsek mezi dvěma opěrnými body se interpoluje zvlášť. Každý úsek interpolační křivky je kubický polynom, tj. polynom třetího stupně na intervalu $\langle x_i, x_{i+1} \rangle$, který nabývá v krajních bodech intervalu zadáných hodnot. V případě kubické interpolace zachovávající tvar musí jednotlivé polynomy dohromady tvořit spojitou funkci pouze do její první derivace, naopak u křivky kubické spline interpolační metody musí být spojitost zabezpečena až do druhého řádu.



Obrázek 16: Příklad kubické a spline interpolace.

Tyto metody jsou v uvedené studii aplikovány na EKG signál vzorkovací frekvence 360 Hz, kdy snižují tuto frekvenci na 250 Hz. K největšímu zkreslení došlo při použití IIR filtrace, znatelně se zkreslil signál i po FIR filtraci. Nejspolehlivější přesnosti dosáhly interpolace kubická a spline, ostatní metody (lineární interpolace, „nejbližší soused“, frekvenční oblast) nezkreslily signál významně, avšak přesnost není zcela vysoká, [8], [37].

2.2. Filtrace ve frekvenční oblasti

Základním způsobem odstranění nežádoucích složek ze signálu jsou frekvenčně selektivní filtry. Patří zde filtry typu horní propust, dolní propust, pásmová zadrž (nebo také notch filtr) a pásmová propust. Hornípropustný (HP) filtr se vyznačuje vlastností propouštět frekvence vyšší než je jeho mezní frekvence a naopak zadržovat frekvence nižší. Je navrhován pro odstranění nízkofrekvenčních trendů, jako je např. vliv dýchání nebo obecně stejnosměrná složka. Dolnípropustný (DP) filtr je jeho opak, tzn., že propouští frekvence nižší než je jeho mezní frekvence. Používá se tedy k odstranění vysokofrekvenčního šumu. Kombinací těchto dvou filtrů je pásmová propust (PP), která má právě dvě mezní frekvence, horní a dolní, které vymezují pásmo propustnosti. Pásmová zadrž (PZ) umožňuje odfiltrování určitého frekvenčního pásma, notch filtr pak odstranění jedné konkrétní frekvence, kdy se uplatňuje při filtraci síťového brumu.

Filtry lze rozdělit na dvě základní skupiny – IIR (s nekonečnou impulsní odezvou) a FIR (s konečnou impulsní odezvou) filtry. Frekvenčně selektivní filtry byly dobře zavedené v analogové oblasti, proto se provedla jejich bilineární transformace k použití také v oblasti digitální, [1], [2].

2.2.1. IIR filtr

Filtr typu IIR vyžaduje minimálně jednu zpětnovazební smyčku. Jeho výhodami je malý řád přenosové funkce, relativně malé zpoždění při zpracování vstupního vzorku a nízké nároky na paměť při výpočtu koeficientů. Naopak jeho nevýhodou může být problém se stabilitou a nelinearita fázové charakteristiky. Přenosová funkce v z -transformaci IIR filtru je vždy racionální funkcí, obsahující jak póly, tak nuly. Lze ji vyjádřit rovnicí (2.2).

$$H(z) = \frac{\sum_{k=0}^M b_k z^{-k}}{1 - \sum_{l=1}^N a_l z^{-l}} = \frac{b_0 + b_1 z^{-1} + \dots + b_M z^{-M}}{1 - a_1 z^{-1} - \dots - a_N z^{-N}}, \quad (2.2)$$

kde a jsou póly, b jsou nuly filtru a N je řád filtru.

K návrhu filtru se používají čtyři typy aproximace amplitudové frekvenční charakteristiky:

- a) Butterworthova aproximace,
- b) Čebyševova aproximace,
- c) Eliptická aproximace.


Všechny typy IIR filtrů jsou rozebrány dále s příklady jejich frekvenčních charakteristik.

Butterworthův filtr

Butterworthův filtr je velmi často používaným typem filtru díky jeho jednoduchosti a maximálně rovné a monotónní odezvy (aproximovaná Taylorovou řadou, viz Obrázek 17). Nevýhodou tohoto filtru je široké přechodové pásmo mezi propustným a nepropustným pásmem, které je však možné zúžit použitím vyššího řádu filtru (avšak za cenu složitější realizace). Přenosová funkce filtru typu DP je definována jako:

$$|H(k)|^2 = \frac{1}{1 + \left(\frac{k}{k_c}\right)^{2N}}, \quad (2.3)$$


kde N je řád filtru, k je index řady diskretní FT (DFT) odpovídající vzorkovací frekvenci. Index DFT řady k_c odpovídá mezní frekvenci ω_c ($k_c = \left\lceil K \frac{\omega_c}{\omega_s} \right\rceil$, kde K je počet bodů řady DFT). ω_c je normalizovaná mezní frekvence a ω_s normalizovaná vzorkovací frekvence. Butterworthův filtr je specifikován jeho mezní frekvencí a řádem N . S rostoucím řádem filtru je jeho odezva rovnější v propustném pásmu a přesun do nepropustného pásma je rychlejší a strmější, [1], [2].



Obrázek 17: Frekvenční charakteristika Butterworthova filtru (DP řádu 10, mezní frekvence 50 Hz).


Čebyševův filtr

Čebyševova aproximace prvního typu se vyznačuje zvlněním v propustném pásmu (aproximuje se Čebyševovým polynomem), naopak nepropustná část je hladká (aproximovaná Taylorovým polynomem, viz Obrázek 18).



Obrázek 18: Frekvenční charakteristika Čebyševova filtru I (DP řádu 10, zvlnění v propustné oblasti 5 dB, mezní frekvence 50 Hz).


Čebyševova aproximace druhého typu neboli inverzní Čebyševova aproximace naopak dovoluje zvlnění v nepropustném pásmu a propustné pásmo je pak hladké (viz Obrázek 19).



Obrázek 19: Frekvenční charakteristika Čebyševova filtru II
(DP řádu 10, zvlnění v nepropustné oblasti 90 dB, mezní frekvence 50 Hz).

Eliptický filtr


V případě tohoto typu filtru jsou obě části frekvenční charakteristiky (viz Obrázek 20), tj. propustná i nepropustná, aproximovány Čebyševovým polynomem a mají tedy zvlněný průběh. Návrh filtru je ze všech uvedených filtrů nejsložitější, avšak umožňuje vytvořit filtr nejnižšího řádu, viz [2], [36].



Obrázek 20: Frekvenční charakteristika eliptického filtru
(DP řádu 10, zvlnění v propustné oblasti 5 dB, v nepropustné oblasti 90 dB, mezní frekvence 50 Hz).

Notch filtr

Nejjednodušším způsobem, jak se zbavit periodického rušení, je vypočítat Fourierovu transformaci (FT) signálu, vymazat nežádoucí složku ze spektra a provést inverzní FT. Notch filtr umožňuje odstranit periodický signál ze spektra, avšak nevýhodou je, že spolu s jeho frekvencí vždy odstraní i několik málo frekvencí z okolí. Může tak způsobit ztrátu informace původního signálu, který už není kompletní, viz [1].



Obrázek 21: Frekvenční charakteristika Notch filtru
(řád 10, mezní frekvence 50 Hz).

2.2.2. FIR filtr

Filtr s konečnou impulsní charakteristikou je na rozdíl od IIR filtrů vždy stabilní, nemá zpětné vazby, může mít lineární fázi a má velký řád přenosové funkce. Nevýhodou je menší strmost přechodného pásma. Návrh FIR filtru je poměrně jednoduchý, avšak jeho průběh je vzdálený ideálním filtrům. Přenosová funkce FIR filtru v z -transformaci je vyjádřena jako:


$$H(z) = \sum_{n=0}^{N-1} h(n) \cdot z^{-n}, \quad (2.4)$$

kde N je řád filtru a h jsou koeficienty filtru.


Princip návrhu FIR filtru vychází z předpokladu, že frekvenční charakteristika filtru je periodická a lze ji reprezentovat jako Fourierovu řadu. Rozvoj frekvenční odezvy do Fourierovy řady se omezí na konečný počet koeficientů, které jsou dále násobeny vhodným oknem, aby došlo k omezení zákmitů ve frekvenční charakteristice. Přehled často používaných oken a jejich definic (kde M je délka okna) je zpracován v Tabulce Tabulka 4. Skutečná výsledná odezva je aproximací požadované charakteristiky, [2], [36].

Tabulka 4: Definice oken FIR filtru.


Bartlett (trojúhelníkové okno)	$w_T(n) = \begin{cases} \frac{n}{M/2}, & 0 \leq n \leq M/2, \\ 2 - \frac{2n}{M}, & \frac{M}{2} \leq n \leq M, \\ 0, & \text{jinde.} \end{cases}$
Hanning	$w_{HN}(n) = \begin{cases} \frac{1}{2} \left(1 - \cos\left(\frac{2\pi n}{M}\right) \right), & 0 \leq n \leq M, \\ 0, & \text{jinde.} \end{cases}$
Hamming	$w_{HM}(n) = \begin{cases} 0,54 - 0,46 \cdot \cos\left(\frac{2\pi n}{M}\right), & 0 \leq n \leq M, \\ 0, & \text{jinde.} \end{cases}$
Blackman	$w_{BL}(n) = \begin{cases} 0,42 - 0,50 \cdot \cos\left(\frac{2\pi n}{M}\right) + 0,08 \cdot \cos\left(\frac{4\pi n}{M}\right), & 0 \leq n \leq M, \\ 0, & \text{jinde.} \end{cases}$




Obrázek 22: Frekvenční charakteristika FIR filtru – Hammingovo okno.
(DP řádu 100, mezní frekvence 50 Hz).



Obrázek 23: Frekvenční charakteristika FIR filtru – Blackmanovo okno.
(DP řádu 100, mezní frekvence 50 Hz).



Obrázek 24: Frekvenční charakteristika FIR filtru – Hannovo okno.
(DP řádu 100, mezní frekvence 50 Hz).



Obrázek 25: Frekvenční charakteristika FIR filtru – Bartlettovo okno.
(DP řádu 100, mezní frekvence 50 Hz).

2.3. Filtrace v časové oblasti

Některé typy signálu mohou být filtrovány přímo v časové oblasti různými metodami zpracování nebo digitálními filtry. Při tomto typu filtrace není vyžadována frekvenční charakteristika signálu ani šumu, často také bývá rychlejší než filtrace v oblasti frekvenční, viz [1].

2.3.1. Synchronizované průměrování

Synchronizované průměrování dokáže oddělit opakující se signál od šumu, aniž by došlo k jeho zkreslení. Pro aplikaci této metody je třeba nejdříve získat počet realizací signálu nebo pozorovaných událostí. Dále je stanoven referenční bod každé této realizace, který slouží jako trigger, kdy je signál získán některým vnějším podnětem (např. EP), nebo detekcí opakující se události v případě quasiperiodického¹⁵ signálu (QRS komplex v EKG, S1 či S2 v FKG). Tyto extrahované části signálu jsou přesunuty do vyrovnávací paměti. V této fázi je důležité mít tyto jednotlivé části signálu zarovnané dle triggeru, jelikož jednotlivé části mohou mít odlišné trvání. Výsledek z paměti je pak vydělen počtem přidávaných událostí/realizací. Pozorovaný signál lze vyjádřit jako:

$$y_k(n) = x_k(n) + \eta_k(n), \quad (2.5)$$

kde $x_k(n)$ zastupuje originální nezarušený signál a $\eta_k(n)$ přidaný šum. $y_k(n)$ pak představuje jednu realizaci signálu, kdy $k = 1, 2, \dots, M$ je její index a $n = 0, 1, 2, \dots, N - 1$ je index vzorku v čase. Pokud pro každou časovou instanci n přidáme M realizací signálu, dostaneme rovnici (2.6).

$$\sum_{k=1}^M y_k(n) = \sum_{k=1}^M x_k(n) + \sum_{k=1}^M \eta_k(n); n = 0, 1, 2, \dots, N - 1. \quad (2.6)$$

Čím větší počet událostí či realizací je zvolen, tím lepšího výsledku SNR je dosaženo, navíc je SNR zlepšeno za předpokladu, že šum je náhodný s nulovou střední hodnotou a nekoreluje s hledaným signálem, [1].

2.3.2. Klouzavý průměr

K odstranění náhodného šumu v časové oblasti při použití pouze jedné realizace signálu lze použít metodu klouzavého průměru. Ta využívá pohyblivého okna, posunujícího se po časové ose signálu. V každé poloze okna je provedena filtrace průměrováním. Filtr klouzavého průměru lze vyjádřit rovnicí (2.7).

$$y(n) = \sum_{k=0}^N b_k x(n - k), \quad (2.7)$$

kde x je vstup a y výstup filtru, b_k jsou koeficienty filtru ($k = 0, 1, 2, \dots, N$, kde N je řád filtru). Filtr realizovaný tímto způsobem je FIR filtrem, tj. má konečnou impulsní charakteristiku, může být realizován bez zpětné vazby a je definován váhami zpoždění. Filtr se chová jako dolní propust s lineární

¹⁵ Empirické signály, které nelze jednoduše analyticky popsat, vykazují však jisté známky periodicity.

fázovou charakteristikou, která je vždy stabilní. Zvýšeného vyhlazení signálu lze dosáhnout použitím delšího časového okna, avšak na úkor zvyšujícího se zpoždění filtru, [1], [2].

2.3.3. Derivace signálu

Metoda derivování signálu umožňuje na rozdíl od výše zmíněných odstranění artefaktů o nízkých frekvencích a eliminuje ty části vstupního signálu, které jsou konstantní. Zároveň tato metoda zesiluje komponenty signálu o vysokých frekvencích. Základní vyjádření derivátoru prvního řádu je následovné:

$$y(n) = \frac{1}{T} [x(n) - x(n-1)], \quad (2.8)$$

kde T je vzorkovací perioda a $x(n)$ vstupní signál. Amplitudová charakteristika derivátoru prvního řádu pak téměř lineárně roste se zvyšující se frekvencí. Výstupní signál je tedy zarušen vysokofrekvenčním šumem. Pro potlačení tohoto rušení lze zároveň použít filtraci klouzavým průměrem (např. dvoubodovým). Fázová charakteristika naopak s rostoucí frekvencí lineárně klesá, [1].

2.4. Adaptivní filtrace

Filtry s fixní charakteristikou, jako jsou váhy či koeficienty, jsou vhodné k úpravě signálů a šumů se stacionární a známou charakteristikou. Návrh frekvenčně selektivních filtrů vyžaduje přesnou znalost obsahu spektra signálu a šumu – tyto filtry tedy nelze využít v případě signálu či šumu, který není stacionární, tj. mění se v čase, a také kdy se signál s rušením významně překrývají (např. EKG matky a plodu). Spektrum signálu je v tomto případě kombinací stejných či podobných frekvenčních rozsahů, proto je nelze od sebe oddělit fixní filtrací. Situace si tedy žádá návrh filtru, který se umí přizpůsobit charakteru rušení, odhadnout a odstranit jej z této směsice signálů k získání jednoho hledaného, [1].

2.4.1. Adaptivní filtr s fázovým závěsem


Metoda adaptivní filtrace s fázovým závěsem (ANC, Adaptive Noise Canceller) využívá dvou vstupů. Primárním vstupem je kombinace hledaného signálu $v(n)$ a šumu $m(n)$, jehož odstranění je cílem této metody:

$$x(n) = v(n) + m(n). \quad (2.9)$$

V tomto zjednodušeném případě je předpokladem, že $v(n)$ a $m(n)$ nejsou korelované. Sekundárním vstupem je pak referenční signál $r(n)$, který nekoreluje s $v(n)$, ale je v těsné korelaci s $m(n)$ v některé z vlastností, která nemusí být známa. Filtr ANC upravuje referenční vstup $r(n)$ tak, aby byl získán signál $y(n)$, velmi blízký šumu $m(n)$. Hledaný signál pak lze vyjádřit jako:

$$\tilde{v}(n) = e(n) = x(n) - y(n). \quad (2.10)$$

Výstup $e(n)$ je dále zapojen do zpětné vazby ANC, aby bylo docíleno co nejmenšího výstupního výkonu signálu. Čím menší je výstupní výkon, tím menší je i šum, obsažený ve výsledném signálu. Minimalizovaným výkonem výstupu je tedy zvýšena hodnota SNR.



Obrázek 26: Blokový diagram funkce ANC.

Filtr lze optimalizovat vyjádřením odchylky $e(n)$ jako vektoru vah a uplatněním procesu volby. Výstup $y(n)$ ve vztahu ke vstupu $r(n)$ je dán jako:

$$y(n) = \sum_{k=0}^{M-1} w_k r(n-k) \quad \tilde{v}(n) = e(n) = x(n) - y(n), \quad (2.11)$$

kde $w_k, k = 0, 1, 2, \dots, M$ jsou váhy a M je řád filtru. Poté může být chyba odhadu $e(n)$ vyjádřena jako

$$e(n) = x(n) - \mathbf{w}^T(n) \mathbf{r}(n), \quad (2.12)$$

kdy T označuje transpozici¹⁶ vektoru a vektor vah $\mathbf{w}(n)$ a vstupní vektor $\mathbf{r}(n)$ jsou definovány jako:

$$\mathbf{w}(n) = [w_0(n), w_1(n), \dots, w_{M-1}(n)]^T(n) = x(n) - \mathbf{w}^T(n) \mathbf{r}(n), \quad (2.13)$$

$$\mathbf{r}(n) = [r(n), r(n-1), \dots, r(n-M+1)]^T. \quad (2.14)$$

Podle takto upraveného vztahu mezi výsledným (hledaným) signálem a vstupními signály již není třeba znát souvislost mezi vstupními signály $v(n)$, $m(n)$ a $r(n)$, jejich statistickou závislost či korelaci. Metoda je tedy vhodná k použití na vstupních signálech, které obsahují jak náhodný nekorelovaný šum, tak i ty deterministické artefakty, jako je rušení elektrorozvodné sítě, signál EKG apod., [1].

2.5. Separace signálů z jejich kombinace

V oblasti biologických signálů je velmi časté měření signálů z různých zdrojů nebo více kanálů, kdy některé z nich způsobí nezávislou informaci nebo redundantní data. Při analýze vícekanálových měření je nutné řešit vztah mezi jednotlivými kanály, potenciální existenci jejich korelace, přítomnost redundance a kvalitu získané informace. Je třeba proto tuto směsici signálů rozdělit na jednotlivé komponenty a ty nežádoucí odstranit. Rozšířené jsou dvě metody, z nichž jedna se zabývá extrakcí nekorelovaných dat (PCA) a druhá statisticky nezávislých dat (ICA), viz [1], [4].

¹⁶ Operace, která způsobí záměnu řádků a sloupců matice/vektoru.

2.5.1. PCA

Metoda analýzy hlavních komponent (PCA) je metodou rozložení signálu na jeho vzájemně nekorelované složky, přičemž uchovává co nejmenší počet dimenzí. Cílem je tedy najít proměnnou, která ponese co nejvíce užitečné informace. Její použití je tedy uplatněno v oblasti odstranění šumu z měřeného signálu. Výchozím předpokladem metody je soubor vzorků signálu reprezentovaný vektorem \mathbf{y} o velikosti $K \times 1$:

$$\mathbf{y} = \mathbf{W}\mathbf{x} = \sum_{k=1}^K x_k \mathbf{W}_k, \quad (2.15)$$

kde $|\mathbf{W}| \neq 0$ a \mathbf{W}_k jsou vektory rozměru $K \times 1$, tvořící ortonormální matici \mathbf{W} , která představuje odhadnutou matici definovanou tak, aby vektor \mathbf{x} , také o rozměru $K \times 1$, dokázal efektivně reprezentovat původní vektor \mathbf{y} . Pro tuto odhadnutou kovarianční matici jsou vypočteny vlastní vektory a vlastní čísla λ_k , což vede k následujícímu odvození kovarianční matice hlavní komponenty \mathbf{x} .

$$\boldsymbol{\sigma}_x = \mathbf{W}^T \boldsymbol{\sigma}_y \mathbf{W} = \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_K \end{bmatrix} = \boldsymbol{\Lambda}, \quad (2.16)$$

kde $\boldsymbol{\Lambda}$ je matice vlastních čísel λ_k , umístěných na její diagonále. Z této rovnice je viditelné, že složky vektoru \mathbf{x} jsou vzájemně nekorelované. Hlavní komponenty jsou seřazeny v sestupném pořadí, tj. $\lambda_1 > \lambda_2 > \dots > \lambda_K$, viz [1], [4].

2.5.2. ICA

Algoritmus analýzy nezávislých komponent (ICA) vychází z předpokladu lineární kombinace nezávislých zdrojů, reprezentovaných vektorem $\mathbf{x}(n)$, s tzv. směšnou maticí \mathbf{M} .

$$\mathbf{y}(n) = \mathbf{M}\mathbf{x}(n), \quad (2.17)$$

kde $\mathbf{y}(n) = [y_1(n), y_2(n), \dots, y_K(n)]$ je vektor K nezávislých komponent (např. měřicích kanálů). Cílem algoritmu je najít tzv. separační matici \mathbf{W} , inverzní ke směšné matici, k nalezení původních signálů

$$\tilde{\mathbf{x}}(n) = \mathbf{W}\mathbf{y}(n). \quad (2.18)$$

Tuto matici lze najít při dvou omezeních, která jsou základními vlastnostmi ICA metody: záměně indexů separovaných komponent $\mathbf{y}(n)$, tzn., že separované zdroje jsou získány v přehrozeném pořadí než zdrojů původních, a zkreslení amplitudy separovaných signálů. Upravením vztahu mezi původními a separovanými zdroji pak lze dosáhnout redukce těchto omezení. Metoda výpočtu separační matice je provedena velkým počtem algoritmů, z nichž některé pracují např. s Gaussovským rozložením atd. Algoritmus ICA je základem metody BSS, která často využívá kombinaci obou metod, PCA a ICA, [1], [4].

2.6. Vlnková transformace

Protože FT má mnoho omezení při zpracovávání nestacionárních signálů (např. časové neomezení sinových funkcí), je třeba hledat řešení pro analýzu těchto signálů v časově-frekvenční oblasti, kam spadá právě metoda vlnkové transformace (WT). Ideou WT je vhodnou změnou šířky mateřské vlnky ψ v čase a jejím tvarem dosáhnout optimálního poměru rozlišitelnosti v čase a frekvenci. Pro nízké frekvence je optimální použít vlnku širší, pro vysoké užší. Pomocí parametru měřítka s je možné měnit její šířku (dilatace) a parametrem polohy τ umístění vlnky na časové ose (translace). Mateřskou vlnku lze definovat vztahem (2.19).

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), \quad (2.19)$$

kde člen $\frac{1}{\sqrt{s}}$ slouží k normalizaci energie vlnky při změnách měřítka. Vlnka je definována dle určitých podmínek – musí mít nulovou střední hodnotu, finitní energii a vhodný frekvenční obsah $\int_0^\infty \frac{|\psi(\omega)|^2}{\omega} d\omega < \infty$.

Spojité WT (CWT, Continuous WT) je pak definována jako:

$$X(\tau, s) = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \bar{\psi}\left(\frac{t-\tau}{s}\right) dt, \quad (2.20)$$

kde symbol $\bar{}$ označuje funkci komplexně sdruženou. Grafické vyjádření koeficientů v rovině (τ, s) se nazývá scalegram neboli vlnková mapa. Vlastnostmi CWT je linearita, časová invariance a dilatace. Rekonstrukce signálu je možná také pomocí diskrétní WT (DWT), která disponuje výhodou rychlejšího výpočtu. Mateřská vlnka je pak dána vztahem:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{s_0^m}} \psi\left(\frac{t - n\tau_0 s_0^m}{s_0^m}\right), \quad (2.21)$$


kde proměnné m a n určují dilataci a translaci vlnky na diskrétní mřížce. Parametry τ_0 a s_0 vyjadřují velikost kroku těchto proměnných. DWT lze pak vyjádřit jako:

$$X(m, n) = \int_{-\infty}^{\infty} x(t) \overline{\psi_{m,n}}(t) dt. \quad (2.22)$$

Níže jsou uvedeny nejčastěji používané typy mateřských vlnek:

- Vlnka **Mexican hat** má tvar druhé derivace průběhu hustoty pravděpodobnosti Gaussova rozdělení. Není ortogonální, proto ji nelze použít v DWT.
- **Morletova** vlnka má tvar komplexní sinusovky modulované Gaussovským oknem. Taktéž není vhodná pro DWT.
- **Meyerova** vlnka je definována ve frekvenční doméně (nikoli v čase). V originálním tvaru ji nelze použít v DWT, ale lze ji diskrétně aproximovat filtry.
- **Haarova** vlnka je jednoduchá vlnka, která ale neumožňuje hladkou rekonstrukci signálu. Bývá nazývána vlnkou Daubechies 1. řádu.

- Vlnka **Daubechies** je na rozdíl od předešlých asymetrická, je ortogonální a lze ji použít jak pro CWT, tak pro DWT. Vlnky Daubechies představují skupinu vlnek různého řádu $N \geq 1$. Kromě vlnky 1. řádu nemají explicitní vyjádření, viz [1], [5], [6].



Obrázek 27: Příklad mateřských vlnek
(zleva Mexican hat, Merletova s čárkovanou imaginární částí, Meyerova).

2.7. EMD

Empirická modální dekompozice (EMD) je metoda rozkladu složeného nestacionárního signálu na určitý počet jednodušších signálů, nazývaných vlastní modální funkce (IMF, Intrinsic Mode Function). Tento proces je založen na výpočtu lokálních charakteristik signálu a k realizaci nepotřebuje žádné předdefinované funkce. Má-li být funkce IMF, musí splňovat následující dvě vlastnosti:

- během jejího trvání se musí počet extrémů rovnat počtu průchodu IMF nulou, nebo se liší nejvýše o jeden,
- v jakémkoli bodě je střední hodnota obálek, definovaných lokálními maximy a minimy, nulová.

Signál IMF nemusí být úzkopásmový. Může být modulován jak ve frekvenci, tak v amplitudě a také nemusí být stacionární. Standardní proces algoritmu EMD je následovný:

1. Hledá body všech extrémů daného signálu $x(n)$.
2. Provádí interpolaci mezi minimy k vytvoření dolní obálky signálu, $x_{min}(n)$ a mezi maximy k výpočtu horní obálky, $x_{max}(n)$. Nejčastěji se využívá kubické spline interpolace.
3. Vypočte střední hodnotu jako $x_m(n) = [x_{min}(n) + x_{max}(n)]/2$.
4. Odečte vypočtenou střední hodnotu, čímž získá modální signál $s(n) = x(n) - x_m(n)$.
5. Pokud $s(n)$ splňuje vlastnosti IMF, definuje $c(n) = s(n)$ a ukládá jako IMF. V opačném případě nastaví $x(n) = s(n)$ a opakuje proces znovu od kroku 1.
6. Tento proces umožní výpočet první IMF. Pro nalezení ostatních IMF je zbytek definován jako $x(n) - c(n)$ a proces se opakuje.

Původní signál je pak součtem všech nalezených IMF. Pomocí Hilbertovy transformace¹⁷ lze dále přesněji definovat jednotlivé IMF a poskytnout tak amplitudu i frekvenci každé této složky jako funkci času, [1], [7].

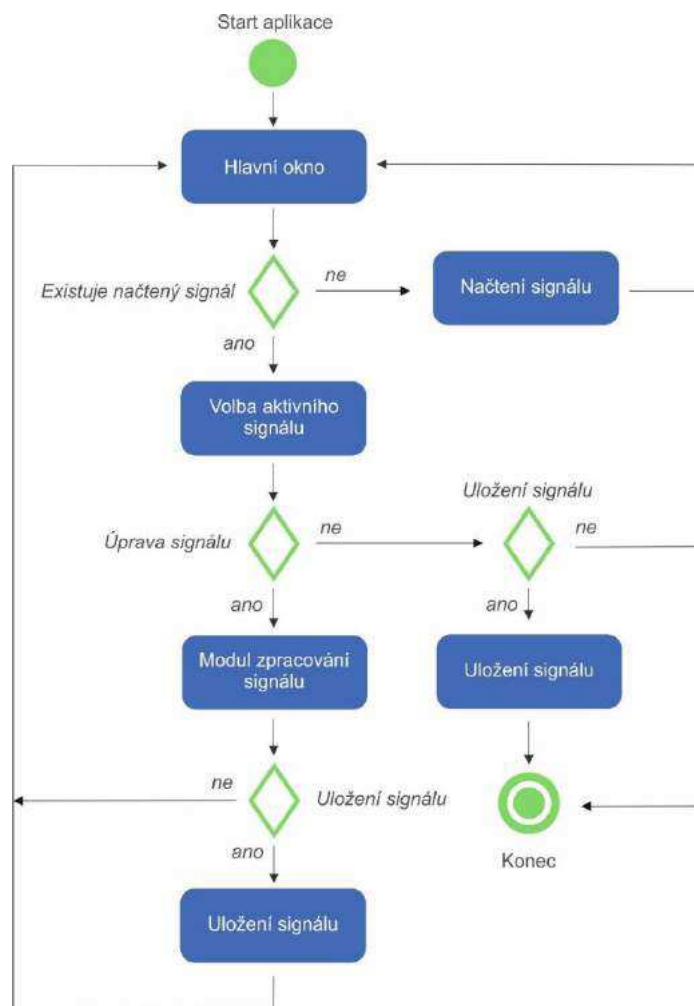
¹⁷ Specifický lineární operátor, který k funkci $u(t)$ vytváří funkci $H(u)(t)$. V časové oblasti je dán konvolucí a ve frekvenčním spektru otáčí původní fázi o 90° . Je používán k výpočtu obálky signálu.

3. Aplikace pro zpracování biologických signálů

V programu MATLAB r2015a bylo vytvořeno uživatelské rozhraní (dále GUI) pro zpracování výše zmíněných biologických signálů (EKG, EEG, EMG, FKG, PPG) a jejich základní analýzu. Výsledný software se skládá z několika hlavních bloků:

- a) načtení signálu, popř. jeho smazání či uložení,
- b) převzorkování signálu interpolačními metodami,
- c) přidání rušení k signálu,
- d) filtrace signálu ve frekvenční i časové oblasti,
- e) další metody zpracování signálu, jako je jeho dekompozice nebo vlnková transformace,
- f) analýza signálu dle jeho původu.

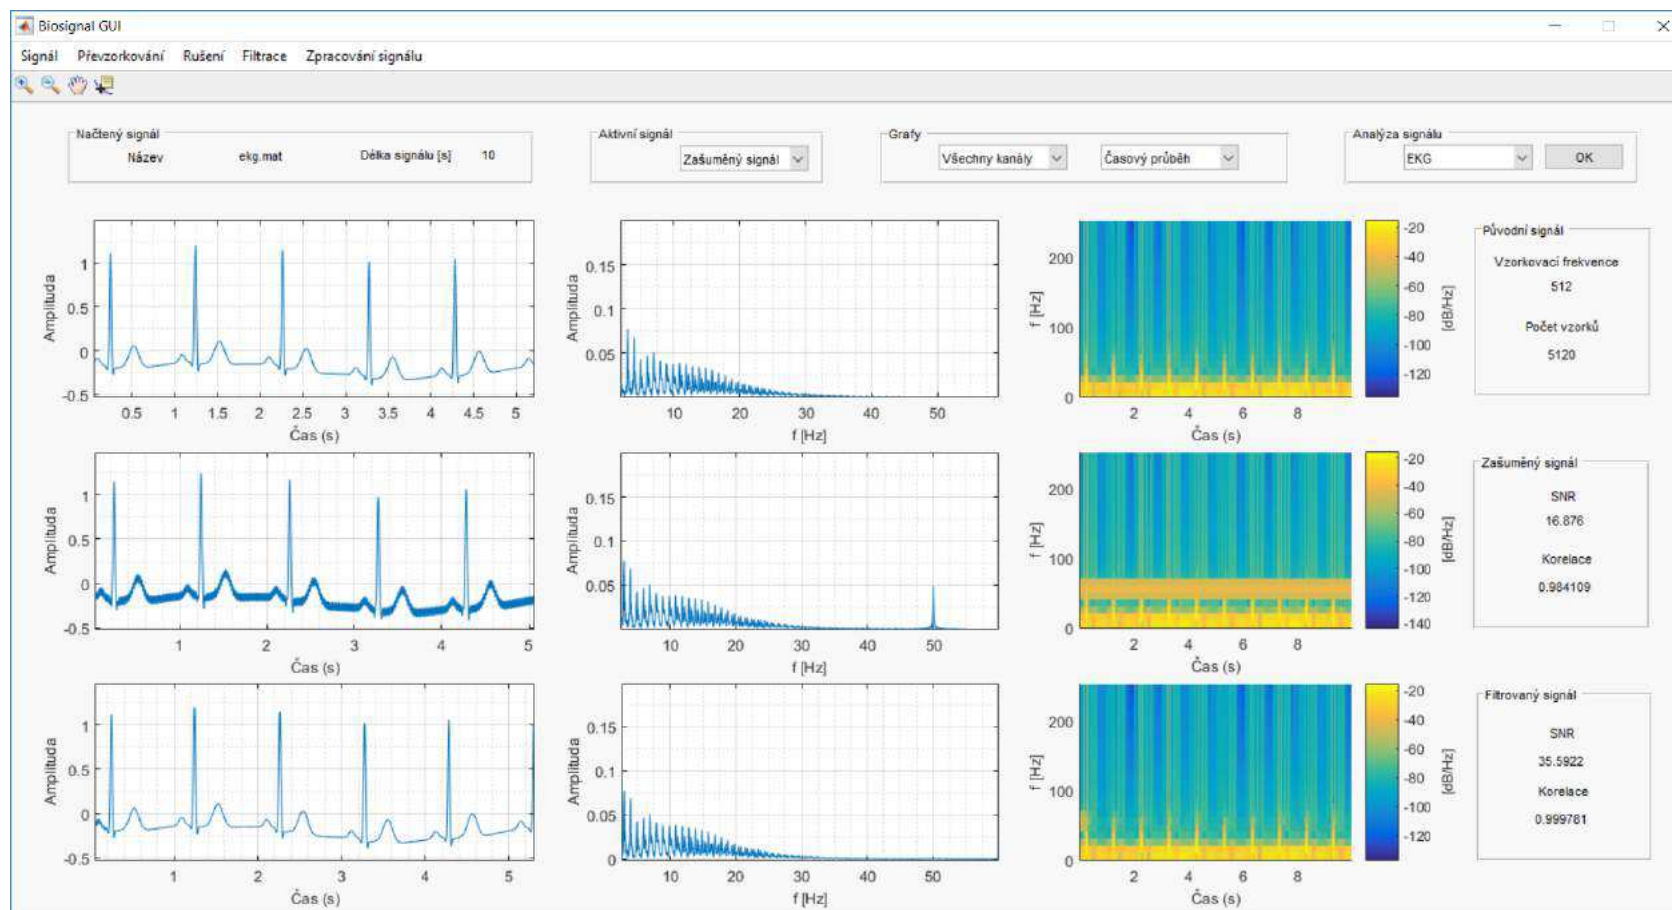
Každý tento blok obsahuje několik modulů, které umožňují signál upravit (typ filtru, konkrétní metoda zpracování signálu, typ rušení). Tyto moduly jsou v podstatě novým grafickým oknem, v rámci něhož uživatel může pracovat se signálem nezávisle na hlavním grafickém okně a rozhodnout se, zda upravený signál zahrne do dalšího zpracování či nikoliv a zvolí metodu jinou. Upravené signály v jednotlivých modulech se ukládají do hlavního grafického okna, kde lze sledovat změny signálu před i po zpracování. Základní architektura softwaru je zobrazena v diagramu (viz Obrázek 28).



Obrázek 28: UML diagram aplikace.

3.1. Funkce GUI

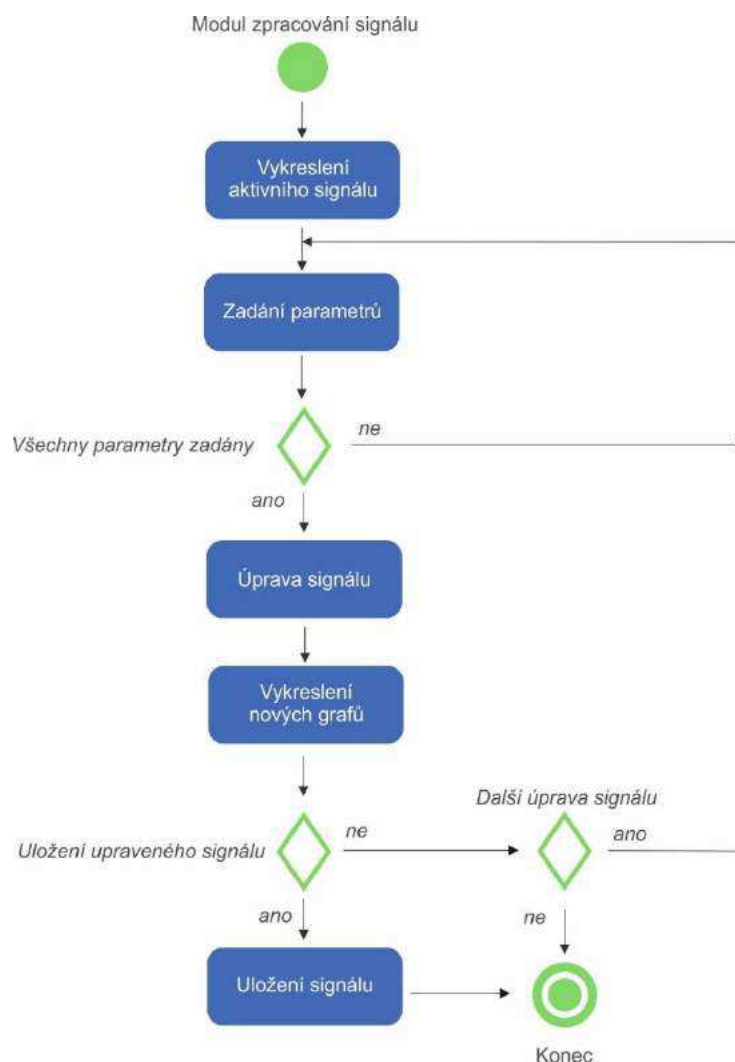
Hlavní GUI aplikace (viz Obrázek 29) obsahuje hlavní menu, kde lze přepínat mezi jednotlivými bloky a moduly aplikace, panely zobrazující některé informace o signálech (délka zpracovávaného úseku, počet vzorků, vzorkovací frekvence, SNR atd.), panel k nastavení grafů a panel k přepínání aktivního signálu, se kterým chce uživatel pracovat. Nedílnou součástí jsou grafy, kde lze vykreslit jednotlivé fáze zpracovávaného signálu (původní, zašuměný a filtrovaný signál) jak v časové, frekvenční (metoda FFT), tak i v časově-frekvenční oblasti (spektrogram, umožňující sledovat výkon na jednotlivých frekvencích v čase). V panelu „Grafy“ lze vykreslovat buď jednotlivé kanály přímo v GUI, nebo v samostatném grafickém okně, kde lze vykreslit také všechny kanály najednou pro lepší přehlednost v matici grafů.



Obrázek 29: GUI aplikace.

3.2. Modul úpravy signálu

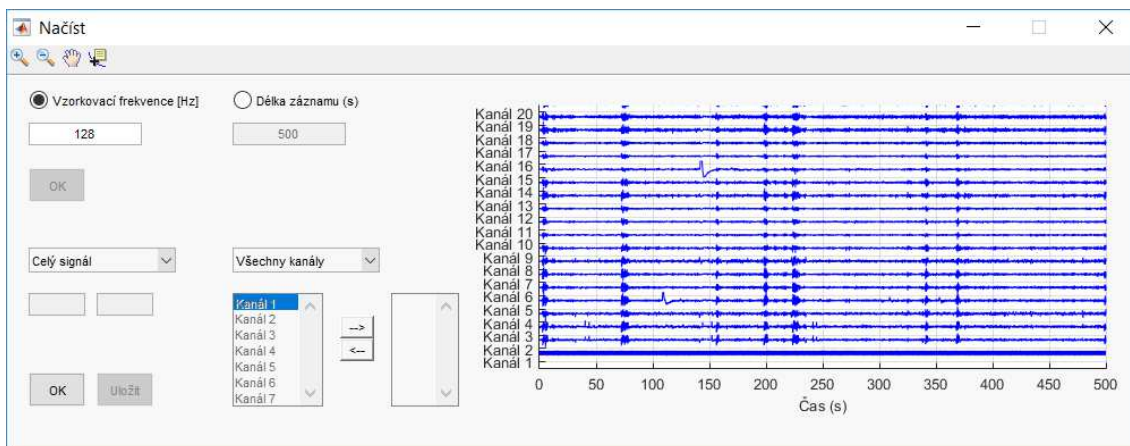
Jak již bylo nastíněno, vytvořený software se skládá z jednotlivých modulů pro úpravu nebo analýzu signálu. Jednotlivé moduly jsou rozříděny do jednotlivých kategorií, které tvoří hlavní menu aplikace – načtení signálu, jeho převzorkování, přidání rušení k signálu, jeho filtrace a další speciální metody zpracování a nakonec jeho analýza, která tvoří samostatnou část a pracuje na odlišném principu než moduly k úpravě signálu. Funkce modulu pro úpravu signálu je znázorněna v diagramu (viz Obrázek 30). Každý modul úpravy signálu umožňuje vybrat kanál, který se v grafech zobrazuje, ale algoritmy metod zpracování signálu pracují se všemi kanály zároveň. Po zadání všech potřebných parametrů metody zpracování se zpřístupní možnost aplikovat daný algoritmus a poté upravený signál uložit. V každém modulu se vykresluje časový průběh původního signálu (resp. aktivního signálu, se kterým uživatel pracuje) a po úpravě také časový průběh nového signálu a jeho jednostranné frekvenční spektrum, vypočítané metodou FFT.



Obrázek 30: UML diagram modulu úpravy signálu.


3.3. Načtení signálu

Aplikace umožňuje načítat data ve formátu *.mat*. Předpokládá se, že tato data jsou uložena v matici, kde každý řádek představuje jeden kanál signálu. Jelikož byly během práce na aplikaci používány především signály z databáze Physiobank, která negeneruje se signálem časovou osu, je nutné znát vzorkovací frekvenci, popř. přesnou délku signálu v sekundách, aby došlo k úspěšnému načtení signálu a výpočtu časové osy. Jeden z těchto parametrů uživatel zadává před samotným načtením do příslušných kolonek, druhý je automaticky dopočítán a signál je vykreslen do grafu (viz Obrázek 31).



Obrázek 31: GUI modulu načtení signálu – celý signál.

Funkcí aplikace je možnost načíst pouze část signálu – tzn. vybrat určitý časový úsek, pokud je signál příliš dlouhý anebo vybrat jen některé kanály k dalšímu zpracování (viz Obrázek 32). Takto upravený signál je uložen do hlavního okna aplikace a je možné s ním nadále pracovat.



Obrázek 32: GUI modulu načtení signálu – vybraný úsek a zvolené kanály.

3.4. Převzorkování signálu

Převzorkovací metody, se kterými aplikace pracuje, jsou lineární interpolace, interpolační metoda nejbližšího souseda, kubická interpolace a spline interpolace. Vzhledem k dostatečně vysokým frekvencím, kterými jsou biologické signály vzorkovány, nedochází k příliš velkému zkreslení při použití rozdílných metod (viz kapitola 2.1). Po uložení interpolovaného signálu se signál ukládá jako původní signál do hlavního GUI a přepíše tedy signál původně načtený. GUI však nabízí možnost obnovení signálu, kdy se automaticky načte ze zálohy právě původně načtený signál, a všechny úpravy jsou ztraceny.

3.5. Rušení signálu


Jak již bylo uvedeno výše, každý biologický signál je sumou nosného signálu s mnoha typy šumu a rušení. Jedná se zejména o rušení z elektrorozvodné sítě, kolísání izolinie, myopotenciály nebo bílý šum. Tyto typy artefaktů umožňuje aplikace nasimulovat a přidat ke zpracovávanému signálu. Signály uložené v modulech pro přidávání rušení jsou do centrálního GUI nahrány jako zašuměný signál.

3.5.1. Síťové rušení

Často vyskytovaným artefaktem ve všech typech biologických signálů je tzv. síťový brum, který vzniká ze zanesení potenciálů z elektrorozvodné sítě do měřicího zařízení. Jeho simulace je založena na přičtení sinusového signálu k signálu původnímu podle

$$z = y + A \cdot \sin(2\pi ft), \quad (3.1)$$


kde y je původní signál, A je amplituda a f frekvence síťového rušení, které uživatel zadá do příslušných vstupů modulu. Frekvence rušení se předpokládá 50 nebo 60 Hz. Amplituda síťového rušení se v praxi pohybuje kolem 10 % maxima signálu.



Obrázek 33: Příklad síťového rušení v signálu EKG (frekvence 50 Hz, amplituda 0,1).

3.5.2. Nízkofrekvenční drift

Nízkofrekvenční složka signálu neboli kolísání jeho izolinie je typické pro rušení dýchacími pohyby, které se nejvýznamněji vyskytují při měření hrudními elektrodami, ale i při dalších měřeních. Dalším příkladem pomalého driftu může být pocení nebo jakékoli jiné artefakty, způsobené pohybem pacienta. Simulace driftu je podobná jako u síťového rušení s tím rozdílem, že sinusová funkce má mnohem menší frekvenci (cca 0,2 – 0,5 Hz).




Obrázek 34: Příklad kolísání izolinie v signálu EKG (frekvence 0,2 Hz, amplituda 0,3).

3.5.3. Trendy

V signálech se často vyskytují některé typy trendů, které se vyznačují různou kombinací vzestupné nebo sestupné tendence signálu. Aplikace umožňuje přidávat k signálu lineární nebo Gaussovský trend. Lineární trend je v podstatě lineární funkce, uživatel tedy nastavuje její koeficient strmosti a posun na y-ové ose. Výsledný signál lze pak zapsat jako

$$z = y + (k \cdot t + b), \quad (3.2)$$

kde y je původní signál, k je strmost funkce trendu a b jeho posun na y-ové ose.




Obrázek 35: Příklad lineárního trendu v signálu EKG (posun 3, strmost 0,2).

V případě Gaussovského trendu je nutno zadat parametry Gaussovy křivky, která průběh tohoto typu trendu charakterizuje, tj. pozici vrcholu a její šířku. Gaussova křivka je v Matlabu vytvořena funkcí *gaussmf* a přičtena k původnímu signálu:

$$z = y + \text{gaussmf}(t, [b \ k]), \quad (3.3)$$


kde y je původní signál, t je čas, b je šířka Gaussovy křivky a k pozice jejího vrcholu.



Obrázek 36: Příklad Gaussovského trendu v signálu EKG (pozice vrcholu 4, šířka 2).

3.5.4. Náhodný šum

Aplikace umožňuje přidávat na konkrétní místa v signálu vysokofrekvenční šum, který při reálném měření může vznikat vlivem činnosti kosterního svalstva (rušení myopotenciály). Lze si tedy zvolit libovolný časový úsek (nebo více úseků) v signálu, kde je přičten náhodný signál o zadané amplitudě.



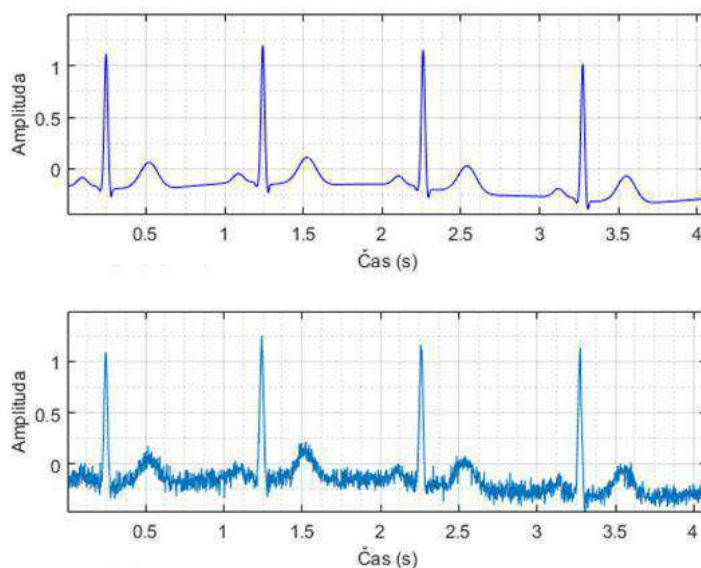
Obrázek 37: Příklad rušení myopotenciály v signálu EKG (časový úsek 5,1 – 5,6 s a 3,5 – 3,7 s, amplituda 0,2).

3.5.5. Bílý šum

Pro testování některých metod zpracování biologických signálů, které vyžadují referenční signál, nebo k simulaci celkového rušení v signálu, způsobeném šumem měřicího zařízení, je v aplikaci možnost generování bílého šumu. Bílý šum je typ signálu, který má na všech frekvencích svého spektra, které je ideálně nekonečné, stejnou amplitudu. Jelikož je to signál náhodný, velice špatně se ze signálu odstraňuje. Bílý šum je generován funkcí *wgn*, kde uživatel prostřednictvím GUI mění pouze výkon šumu:

$$z = y + wgn(k, x, p), \quad (3.4)$$

kde y je původní signál, k je počet kanálů signálu, x je počet vzorků signálu a p je výkon bílého šumu v dB.




Obrázek 38: Příklad bílého šumu v signálu EKG (výkon šumu -25 dB).

3.6. Filtrace signálu

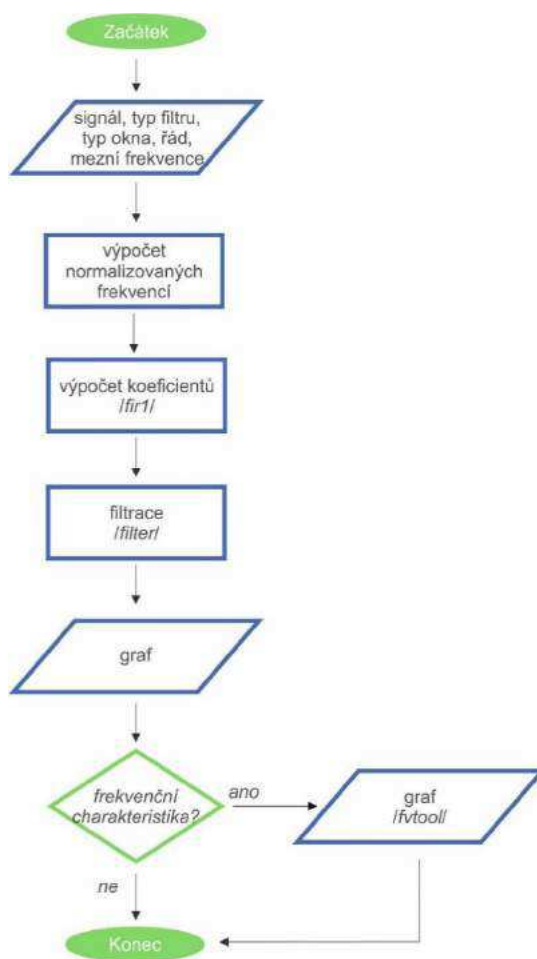
Základním krokem ve zpracování signálu je jeho filtrace. V aplikaci lze navrhovat filtry jak ve frekvenční oblasti (FIR, IIR filtry), tak i v oblasti časové (klouzavý průměr). Signál uložený v modulu spadajícím pod kategorii filtrace signálu je uložen do hlavního GUI jako signál filtrovaný. Všechny zde popsané filtrační metody jsou blíže rozebrány v kapitolách 2.2, 2.3 a 2.4.

3.6.1. FIR filtr

Filtr typu FIR je co do návrhu nejjednodušším filtrem. Charakteristika filtru je dána pouze jeho řádem a mezními frekvencemi. Modul FIR filtrace umožňuje volbu typu filtru – DP, HP, PP, PZ a typu okna (Hammingovo, Blackmanovo, Hanningovo nebo Bartlettovo). Dle zadaných kritérií (mezní frekvence a řád filtru) je navržen filtr funkcí *fir1* a provedena filtrace signálu. Společně se samotnou filtrací je možné vykreslit frekvenční charakteristiku navrženého filtru (funkce *fvtool*, kde lze zobrazovat všechny parametry filtru ve frekvenční oblasti – odezva amplitudy, fáze, skupinové zpoždění atd.).




Obrázek 39: Příklad FIR filtrace signálu EMG (PP, Hammingovo okno, mezní frekvence 50 a 150 Hz, řád filtru 100).



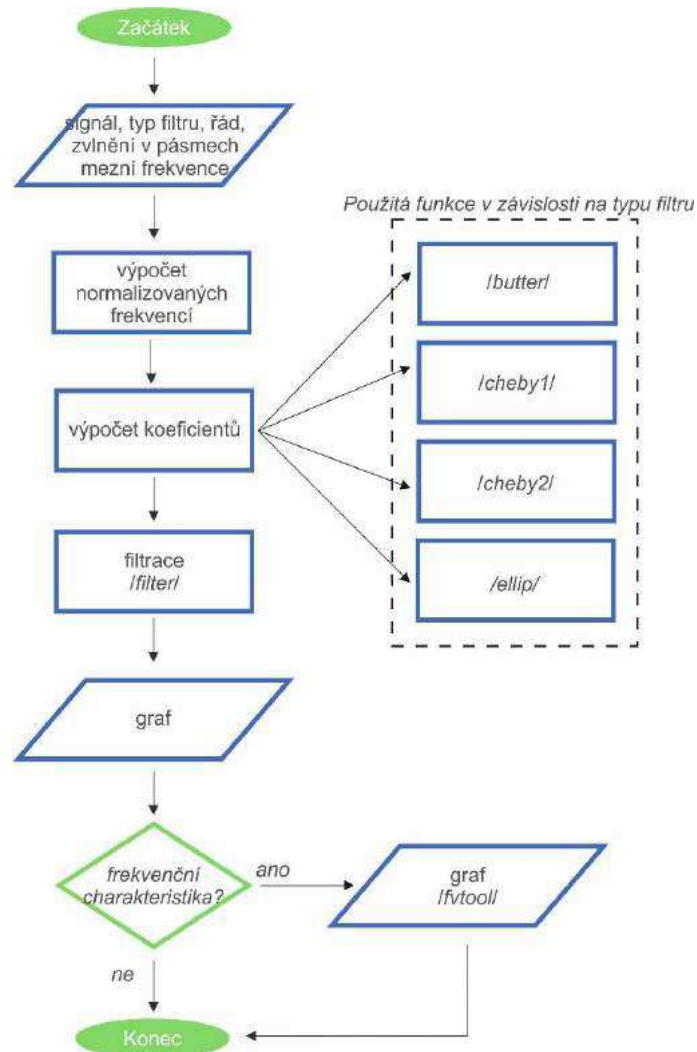
Obrázek 40: Vývojový diagram FIR filtru.

3.6.2. IIR filtr

Filtr typu IIR je složitějším typem filtru, kdy při jeho návrhu nemusí stačit jen řád a mezní frekvence. Nejjednodušším typem je filtr Butterworthův (funkce *butter*), kde si uživatel vystačí právě s těmito dvěma kritérii. Dalšími typy je pak filtr Čebyševův (prvního a druhého typu – funkce *cheby1a cheby2*), kde je dalším nutným parametrem pro návrh filtru zvlnění v propustné nebo nepropustné oblasti (v jednotkách dB), a eliptický filtr (funkce *ellip*), který umožňuje kombinovat všechny výše zmíněné parametry. Řád IIR filtru bývá mnohem menší než je zvykem u filtru typu FIR. Opět je nutné zvolit typ filtrace (PP, PZ, HP, DP).




Obrázek 41: Příklad IIR filtrace signálu FKG – odstranění bílého šumu (DP, Butterworth, mezní frekvence 500 Hz, řád filtru 10).



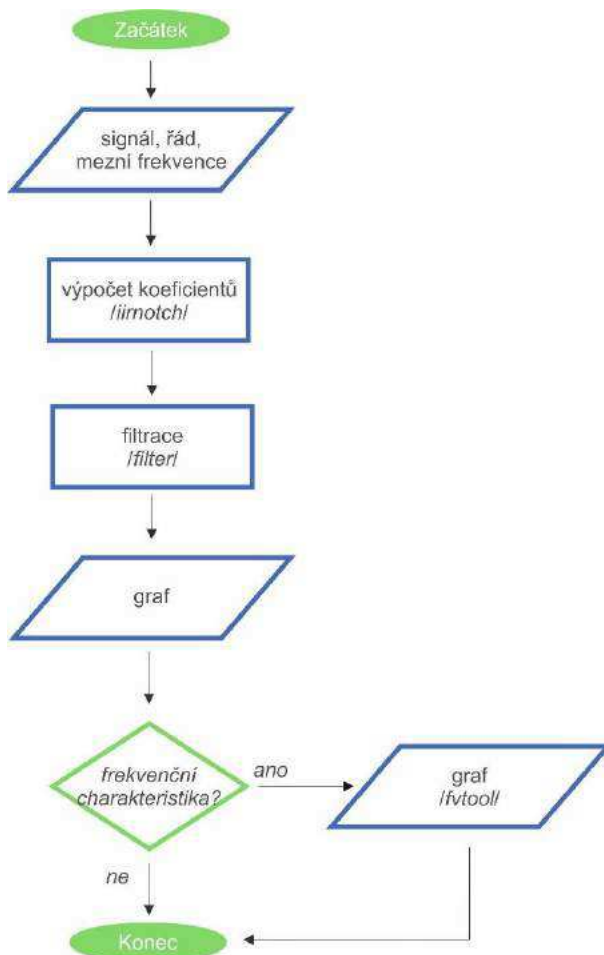
Obrázek 42: Vývojový diagram IIR filtru.

3.6.3. Notch filtr

Speciálním typem filtrace ve frekvenční oblasti je notch filtr. Jedná se v podstatě o IIR pásmovou zádrž, avšak pouze na jedné frekvenci. Ideální je k filtraci síťového rušení, kdy známe frekvenci, se kterou rušení osciluje. Účinnost filtrace lze změnit řádem filtru – čím nižší řád je zvolen, tím více frekvenčních složek kolem zadané mezní frekvence je odstraněno a dochází k dalšímu zkreslení signálu. Filtr je realizován funkcí *iirnotch*.




Obrázek 43: Příklad notch filtrace signálu EMG – odstranění síťového rušení (mezí frekvence 50 Hz, řád 50).




Obrázek 44: Vývojový diagram notch filtru.

3.6.4. Klouzavý průměr

Klouzavý průměr je příkladem filtrace v časové oblasti, kdy je počítán průměr hodnot signálu v pohyblivém okně určené šířky. Tímto umožňuje vyhladit signál i v silně zarušených místech.



Obrázek 45: Příklad filtrace klouzavým průměrem signálu PPG – odstranění myopotenciálů (řád filtru 20).




Obrázek 46: Vývojový diagram klouzavého průměru.

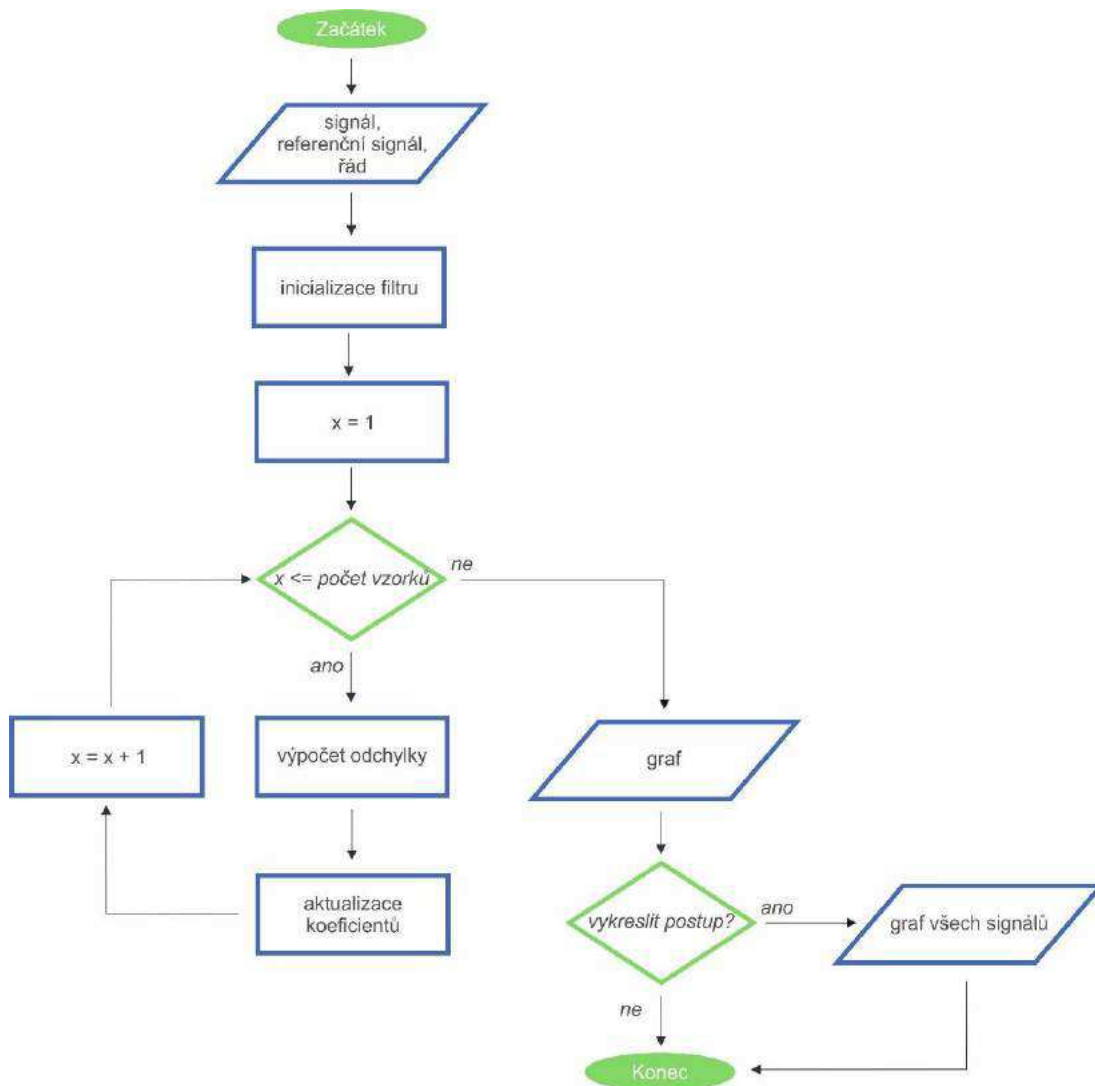
3.6.5. ANC

Realizace ANC filtru je odlišná od ostatních filtrů především tím, že ke své funkci potřebuje referenční signál, se kterým je vstupní signál porovnáván. Naopak zde není možnost určení mezní frekvence, jelikož je filtr navržen pro filtrování signálů se stejným nebo neznámým frekvenčním rozsahem.

Modul umožňuje použití bílého šumu nebo sinusové funkce s frekvencí 50 Hz jako referenčního signálu, nebo nahrání signálu ze souboru. V tomto případě je otevřeno nové grafické okno pro nastavení referenčního signálu v čase (obdobně jako u načítání signálu lze zvolit časový úsek), volbu jednoho kanálu z načtené matice a zobrazení v grafu. Filtrace je provedena RLS filtrem (Recursive Least Squares), který využívá jako kritériální funkci sumu váhovaných čtverců chybového signálu (odchylky referenčního signálu od vstupního). Jeho výhodou je rychlá konvergence k optimálním koeficientům filtru. Funkce implementovaného RLS filtru je znázorněna v diagramu (viz Obrázek 48).



Obrázek 47: Příklad ANC filtrace signálu abdominálního EKG (řád filtru 10, referenční signál hrudního EKG matky).




Obrázek 48: Vývojový diagram ANC filtru.

3.7. Metody zpracování signálu

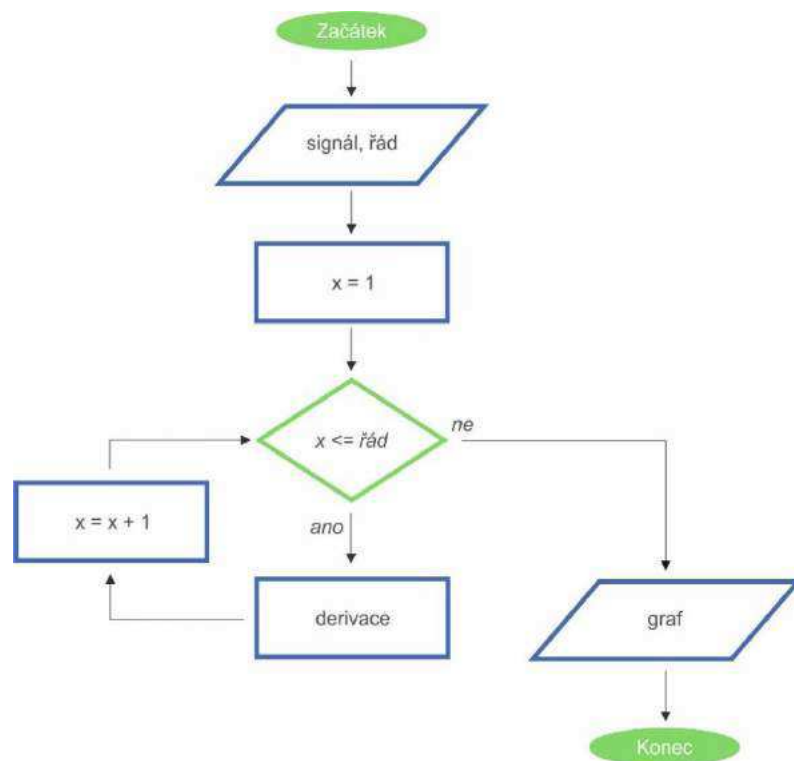
Pokud se v signálu vyskytují složitější artefakty (např. z jiných měřených signálů) nebo je naměřený signál směsicí několika různých signálů, je možné je zpracovat metodami zcela odlišnými od typické filtrace. Jedná se o metodu WT, PCA, ICA a EMD. Všechny použité metody jsou teoreticky nastíněny v kapitolách 2.5, 2.6 a 2.7.

3.7.1. Derivace

Derivace je jednoduchým nástrojem, jak v signálu zvýraznit vrcholy a utlumit zbytek signálu. Používá se především u detektoru vrcholů (viz kapitola 3.8.1), avšak může posloužit i při jiných aplikacích zpracování signálu. Pro derivaci signálu je použita funkce *diff* tolikrát, než algoritmus dosáhne řádu derivace, zadaného uživatelem. Derivovaný signál je pro vyhlazení ještě filtrován klouzavým průměrem řádu 10.




Obrázek 49: Příklad derivace signálu EKG.



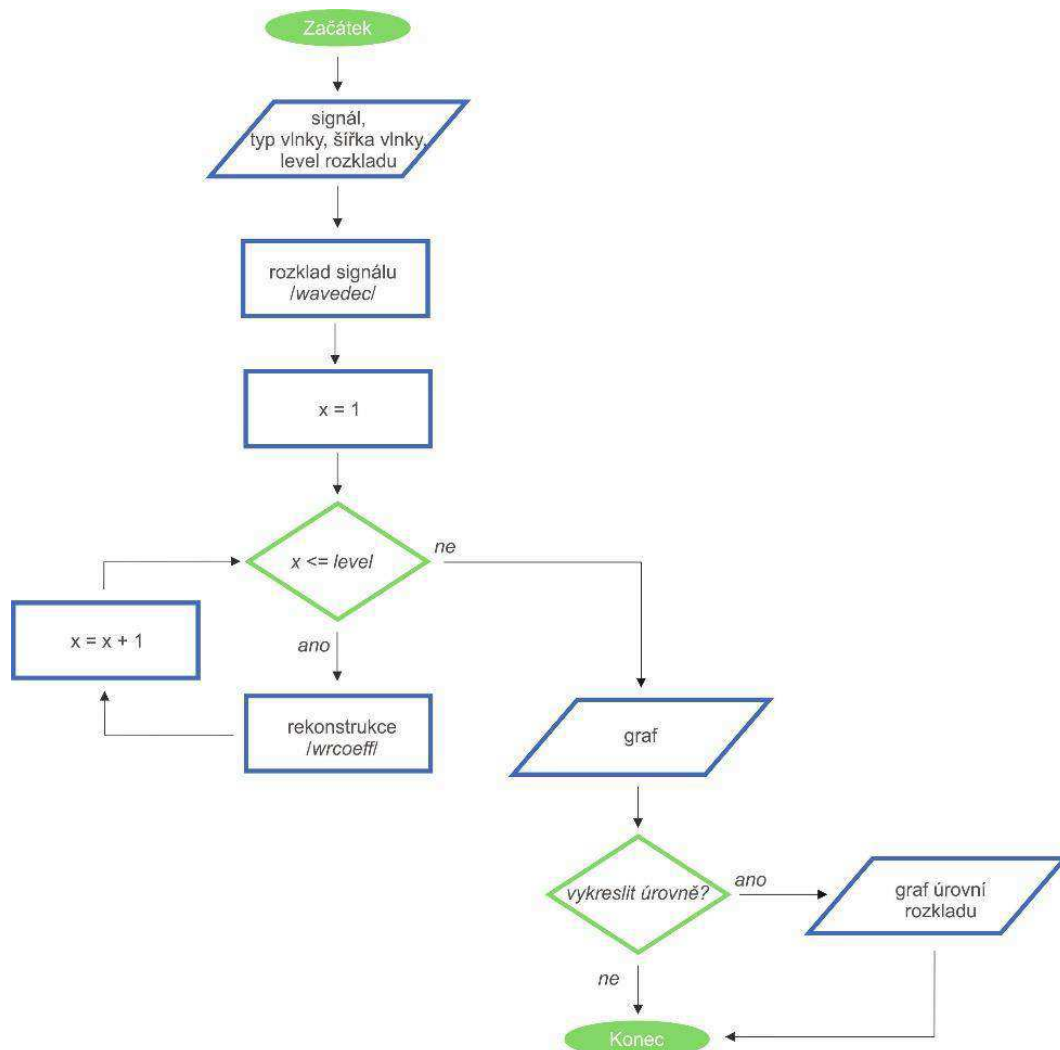
Obrázek 50: Vývojový diagram derivace signálu.

3.7.2. WT

Metoda WT se používá nejčastěji k filtraci nestacionárních (EMG, EEG), ale i jiných signálů, jelikož lze zvolit z mnoha předvolených typů mateřských vlnek, jejichž tvar často odpovídá hlavním znakům zpracovávaného signálu (QRS komplex u EKG, S1 u FKG atd.). Modul aplikace pro WT nabízí volbu mateřské vlnky Daubechies, Coifletovu, Symletovu a Meyerovu ve všech jejich dostupných šířkách. Proces WT je navržen jako rozklad signálu na jednotlivé úrovně pomocí zvolené vlnky (funkce *wavedec*) a následné rekonstrukce signálu z vypočtených koeficientů (funkce *wrcoef*).




Obrázek 51: Příklad WT signálu FKG (vlnka sym10, úroveň rozkladu 9).



Obrázek 52: Vývojový diagram WT.

3.7.3. PCA

Algoritmus PCA hledá v signálu předem určený počet nekorelovaných funkcí, ze kterých je signál složen. Princip spočívá ve výpočtu metodou singulárního rozkladu *svd* a lze ji aplikovat pouze na vícekanálové signály (matici signálů). Výsledné komponenty jsou seřazeny dle svého výkonu od nejvyššího po nejnižší. Typickým příkladem použití je detekce fetálního EKG ze signálu, měřeného na břicho matky. Naměřený signál je tak kombinací obou signálů (matky a plodu), ze kterého lze v případě multikanálového měření právě metodou PCA fetální EKG obdržet. Při výpočtu hlavních komponent jsou vykresleny všechny komponenty zvlášť do grafického okna a následně je možné v modulu vykreslit pouze jednu komponentu, která je pak uložena do hlavního GUI jako filtrovaný signál. Jelikož je podmínkou zpracování touto metodou vícekanálový signál, zvolená komponenta se uloží do všech kanálů signálu.



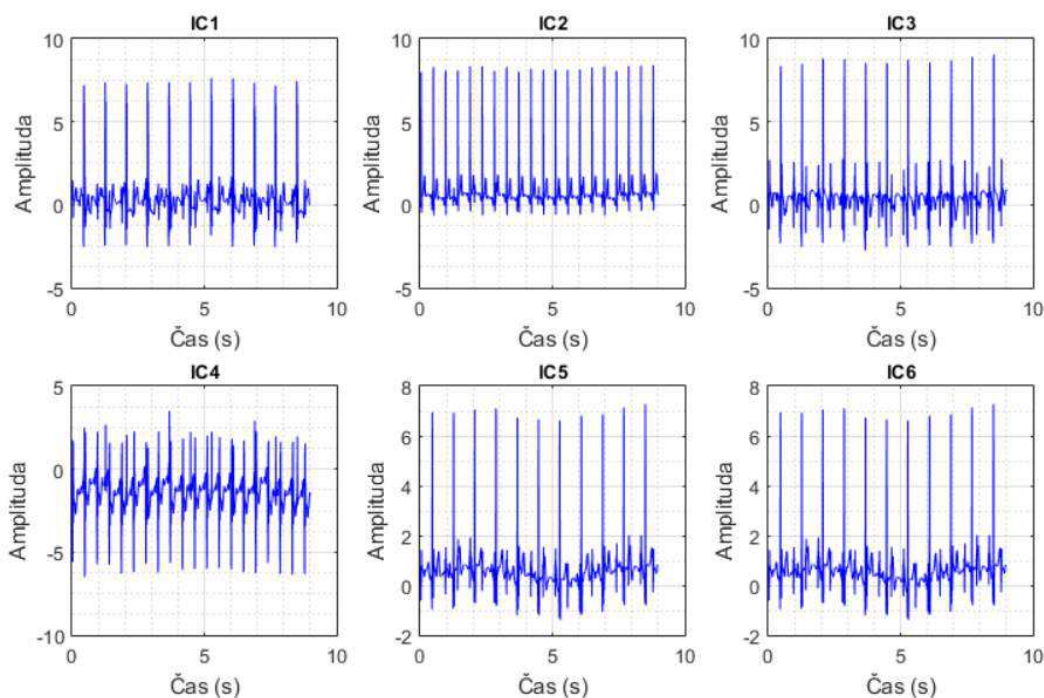
Obrázek 53: Příklad hlavních komponent abdominálního EKG signálu (PC1 odpovídá EKG signálu matky, PC2 pak signálu plodového EKG).



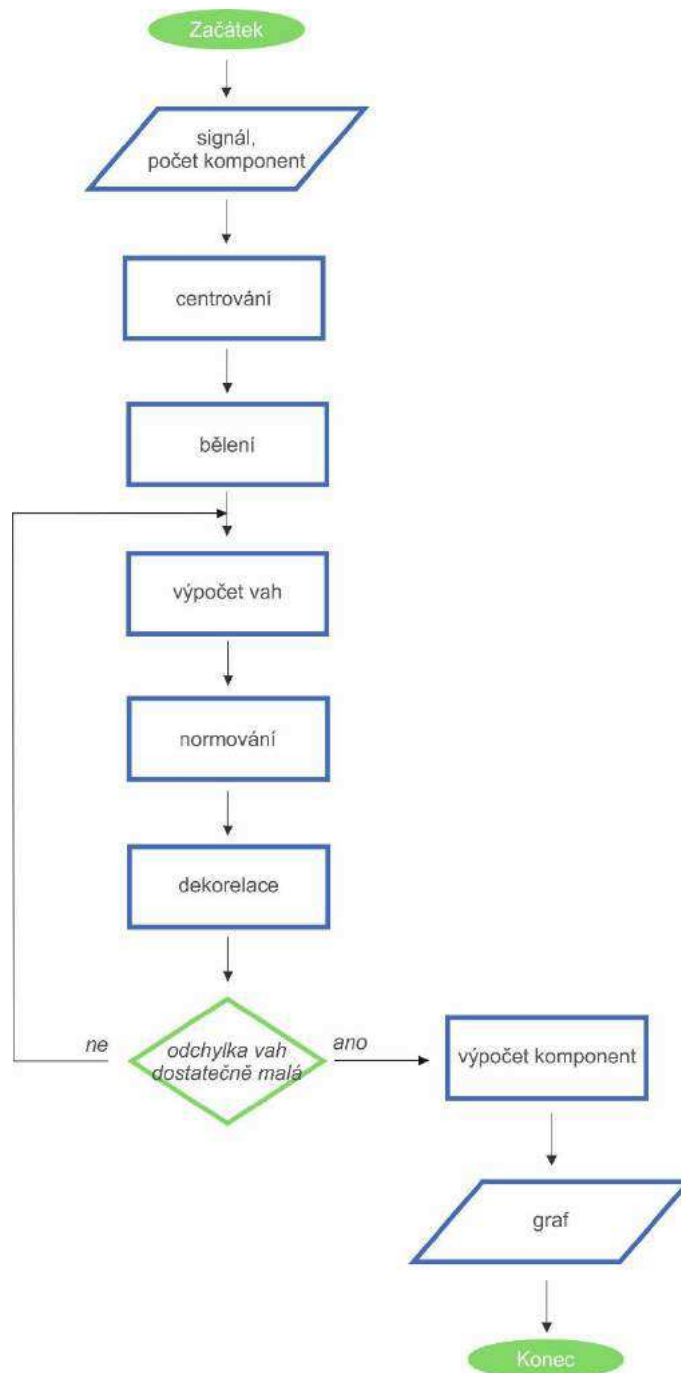
Obrázek 54: Vývojový diagram PCA.

3.7.4. ICA

Metoda ICA je založena na předpokladu, že se zpracováváný signál skládá z několika neznámých signálů, pocházejících z různých zdrojů. Na rozdíl od metody PCA se komponenty seřazují náhodně a jsou výrazně pozměněny v amplitudě. Ze směsice signálů lze vypočítat mnohem více nezávislých komponent než je počet zdrojů signálů v ní obsažených (na rozdíl od metody PCA, kde je počet hlavních komponent limitován počtem zdrojů). Použit byl algoritmus *fastICA*, popsáný diagramem níže (viz Obrázek 56). Obdobně jako u metody PCA, i zde při výpočtu nezávislých komponent jsou vykresleny všechny komponenty zvlášť do grafického okna a následně je možné v modulu vykreslit pouze jednu komponentu a uložit do hlavního GUI jako filtrovaný signál, jehož všechny kanály obsahují tuto zvolenou komponentu.




Obrázek 55: Příklad nezávislých komponent abdominálního EKG signálu (IC2 nejlépe odpovídá signálu plodového EKG).



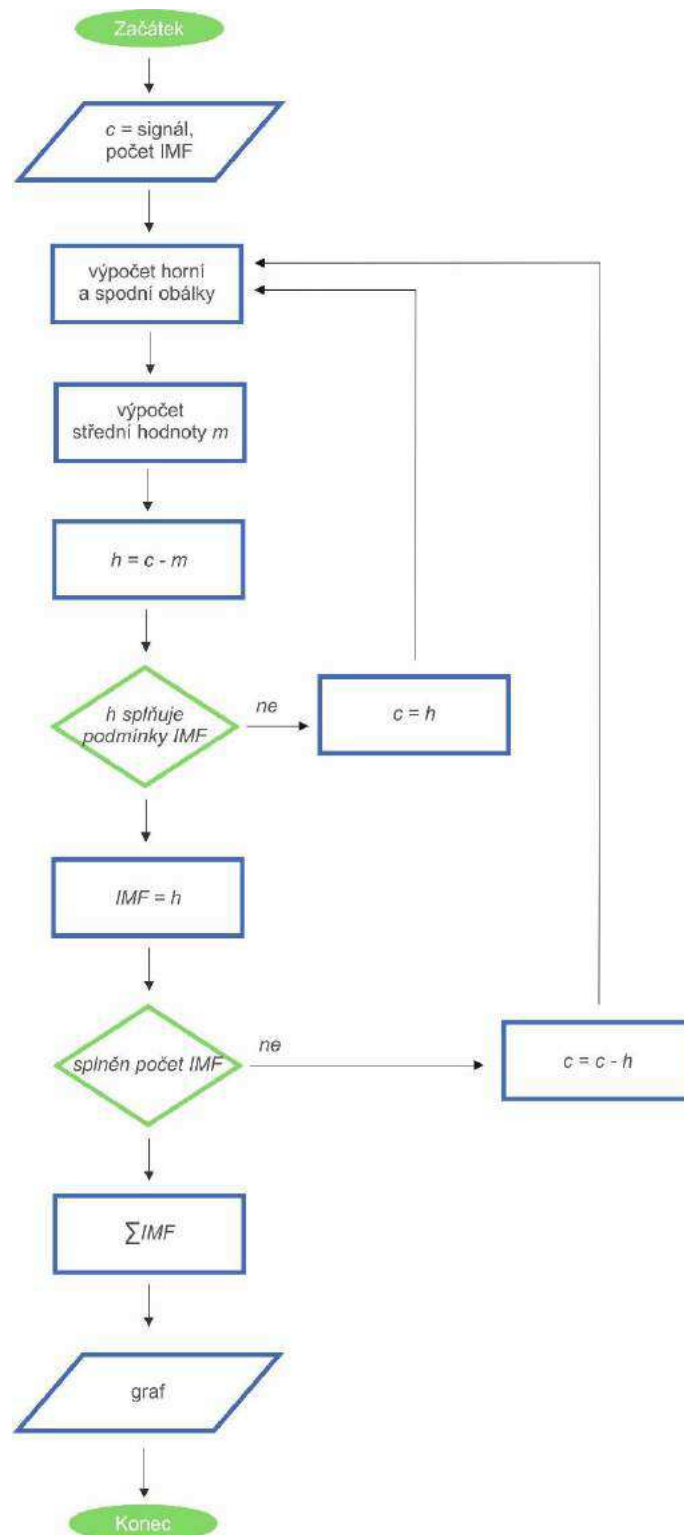
Obrázek 56: Vývojový diagram fastICA.

3.7.5. EMD

Metoda EMD (viz Obrázek 58) je účinnou metodou v odstraňování trendů a nízkofrekvenčního rušení. Rozkládá signál na jednotlivé modální funkce a jejich součtem vzniká signál nový. Algoritmus metody je ovlivněn počtem IMF, který uživatel zadává prostřednictvím GUI. Nabízí opět možnost vykreslit všechny IMF jednotlivě v matici grafů v novém grafickém okně.



Obrázek 57: Příklad metody EMD na signálu EEG – odstranění lineárního trendu (počet IMF = 10).

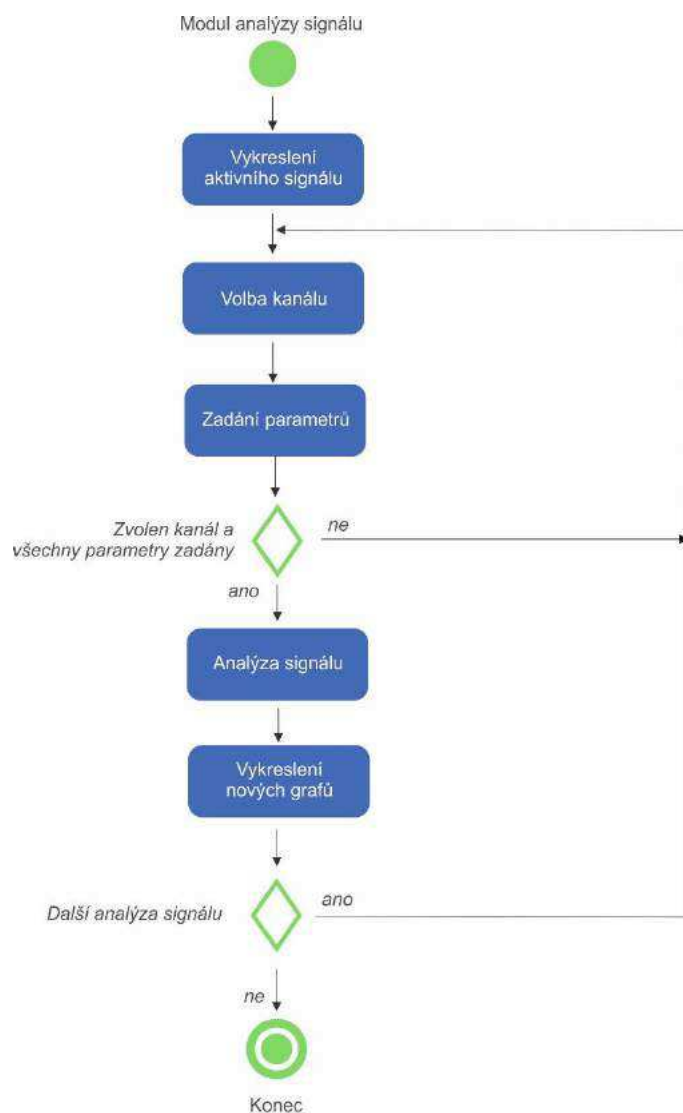


Obrázek 58: Vývojový diagram EMD.

3.8. Analýza signálu

Posledním blokem v řetězci zpracování signálu je jeho analýza. Navržená aplikace umožňuje základní analýzu nejčastěji používaných biologických signálů v diagnostice (viz kapitola 1). V případě EKG, FKG a PPG je to detektor vrcholů, jelikož se všechny tyto signály používají (mimo jiné) k výpočtu tepové frekvence. V případě EMG je to analýza výskytu nenulového signálu v průběhu měření a jeho obálky a analýza EEG je zaměřena na hodnocení výkonu v jeho jednotlivých frekvenčních pásmech.

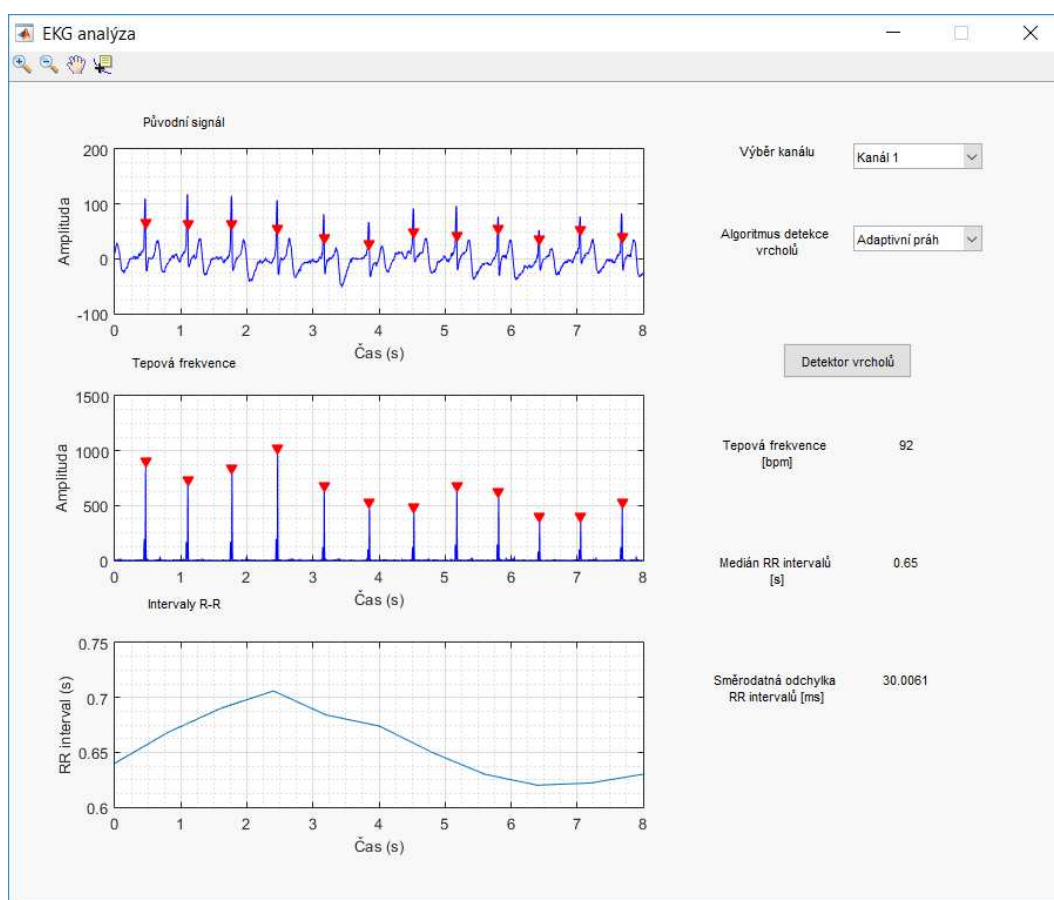
Modul analýzy signálu se poněkud liší od modulu úpravy signálu, a to především tím, že v případě vícekanálového signálu umožňuje zpracování pouze jednoho vybraného kanálu. Dalším rozdílem je chybějící možnost dále signál ukládat (viz Obrázek 59).



Obrázek 59: UML diagram modulu analýzy signálu.

3.8.1. Detektor vrcholů EKG a FKG

Detekce vrcholů je zajištěna dvěma různými algoritmy, z nichž jeden pracuje s pevným a druhý s adaptivním prahováním. Základem obou algoritmů je umocnění signálu nebo výpočet jeho absolutní hodnoty, dále derivace signálu a vlastní detekce vrcholů. V případě EKG jsou detekovány R vrcholy, u FKG jsou to vrcholy S1. Ze získaných vrcholů jsou nadále vypočítány intervaly, které jsou v diagnostice významnými ukazateli funkce stavu srdečního i nervového systému (především autonomního, který srdce řídí). Srdeční variabilita, získaná z těchto intervalů, je užívána k diagnostice mnoha patologických stavů a nemocí myokardu či ANS. V modulu je zobrazena průměrná tepová frekvence, vypočítán medián intervalů mezi zjištěnými vrcholy a jejich směrodatná odchylka.



Obrázek 60: Příklad modulu analýzy EKG.

Detektor vrcholů s pevným prahem

Princip jednoduššího z algoritmů detekce vrcholů je znázorněn v diagramu (viz Obrázek 61). Je založen na stanovení pevného prahu, který se počítá z maximální amplitudy původního signálu (algoritmus počítá s 30 % maxima). Dále je vypočtena absolutní hodnota signálu. Všechny hodnoty takto upraveného signálu, které jsou menší než stanovený práh, jsou položeny hodnotě tohoto prahu. Dalším krokem je derivace signálu, která je použita k vlastní detekci vrcholů (práh je stanoven na 30 % maxima derivovaného signálu). Algoritmus počítá s minimální vzdáleností mezi vrcholy – ta je nastavena na 200 ms, jelikož kratší vzdálenost by již nebyla fyziologická.



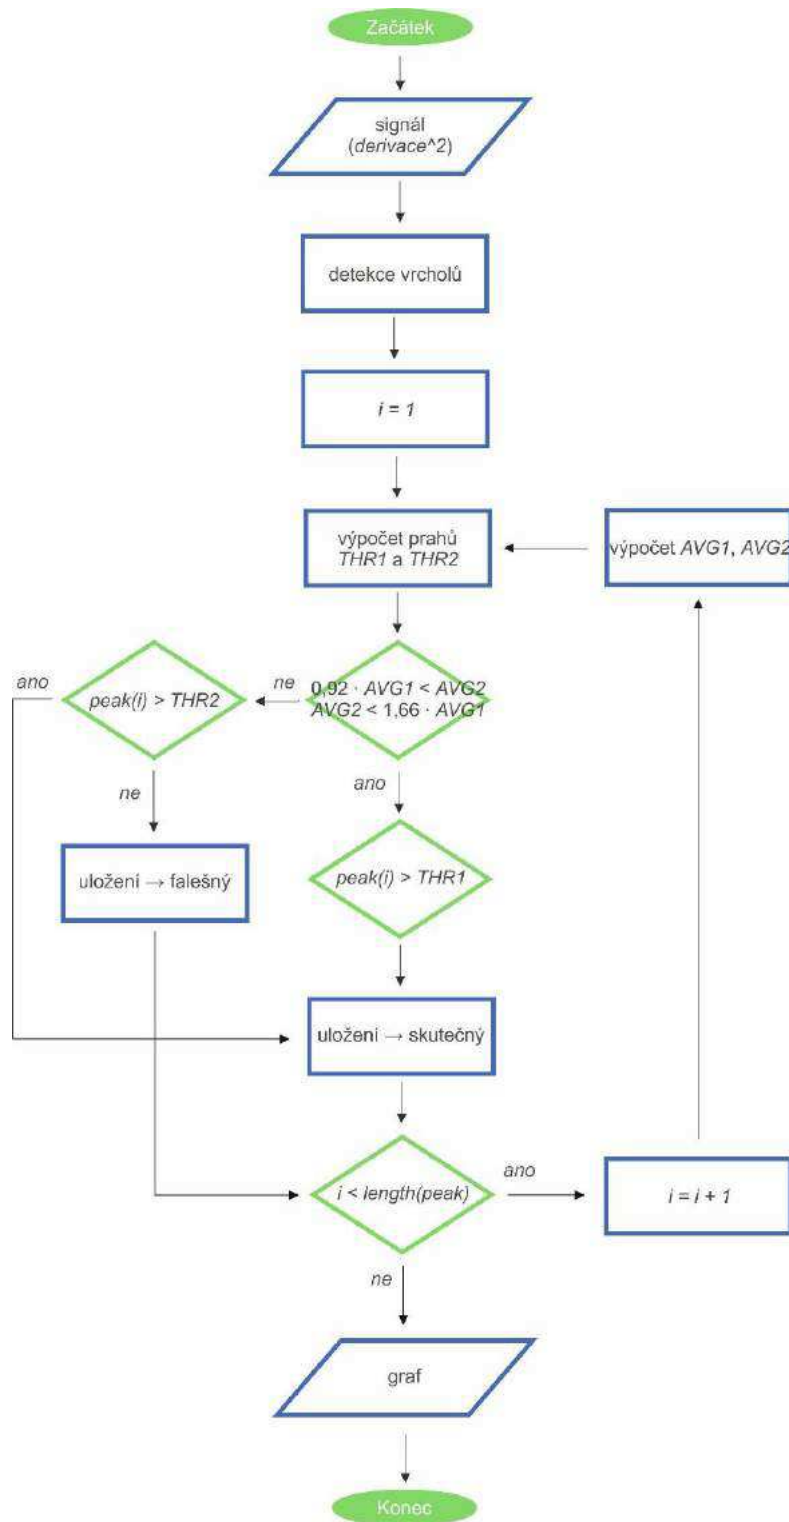
Obrázek 61: Vývojový diagram detekce vrcholů s pevným prahem.

Adaptivní detektor vrcholů

Algoritmus adaptivní detekce vrcholů je realizován poněkud složitěji než algoritmus popsany výše, avšak jeho úspěšnost správného určení vrcholů je vyšší než 99 %. Je založen na principu dvou prahů, detekci všech vrcholů a jejich následné klasifikaci (viz Obrázek 62). Prvním krokem je inicializační fáze, která využívá prvních 4 sekund derivovaného a umocněného záznamu a sestává z detekce všech vrcholů v tomto úseku. Následovně je určen práh jako 60 % z maxima tohoto úseku a první amplituda, která přesahuje tento práh, je dále uložena jako skutečný vrchol. Poslední amplituda, která tohoto prahu nedosáhla, je uložena jako falešný vrchol. Ostatní vrcholy jsou detekovány pomocí nového prahu (*THR1*), určeného jako 25 % z rozdílu těchto dvou nalezených vrcholů (skutečného a falešného) a je vypočten interval mezi vrcholy. V další fázi jsou hledány vrcholy ve zbytku záznamu s použitím prahu *THR1* a nového prahu (*THR2*), stanoveného jako 50 % *THR1*.

Vzhledem ke skutečnosti, že se hodnoty vrcholů často mění, může být skutečný vrchol detekován jako vrchol falešný. Tento případ je ošetřen zpětným vyhledáváním, které je založeno na analýze intervalů mezi vrcholy. Po detekci každého skutečného vrcholu je počítána průměrná délka z posledních


osmi intervalů ($AVG1$). Pokud je průměrná hodnota posledních osmi intervalů po dalším detekovaném vrcholu ($AVG2$) v zadaném rozmezí ($0,92 \cdot AVG1 < AVG2 < 1,66 \cdot AVG1$), je hodnota uložena jako skutečný vrchol. V opačném případě rozhoduje $THR2$ o klasifikaci vrcholu (pokud je hodnota vrcholu nižší, je uložen jako vrchol falešný).




Obrázek 62: Vývojový diagram adaptivního detektoru vrcholů.

3.8.2. Detektor vrcholů PPG

Detekce vrcholů PPG využívá stejných algoritmů jako u analýzy EKG a FKG s jedním rozdílem – v rámci algoritmů není provedena derivace ani umocňování či absolutní hodnota, jelikož se PPG signál v těchto případech chová zcela odlišně od signálů ostatních. Oproti tomu je v modulu nabídka volby, zda se má detekce vrcholů aplikovat na derivovaný signál, či nikoliv. Derivace PPG signálu umožňuje lepší detekci vrcholů v případě, že obsahuje výraznou dikrotickou vlnu a tepová frekvence je počítána v podstatě z počátků P vlny (při nulové izolínii průchody signálu nulou).



Obrázek 63: Příklad derivace signálu PPG.



Obrázek 64: Porovnání detekce vrcholů z původního (nahore) a derivovaného (dole) signálu PPG.

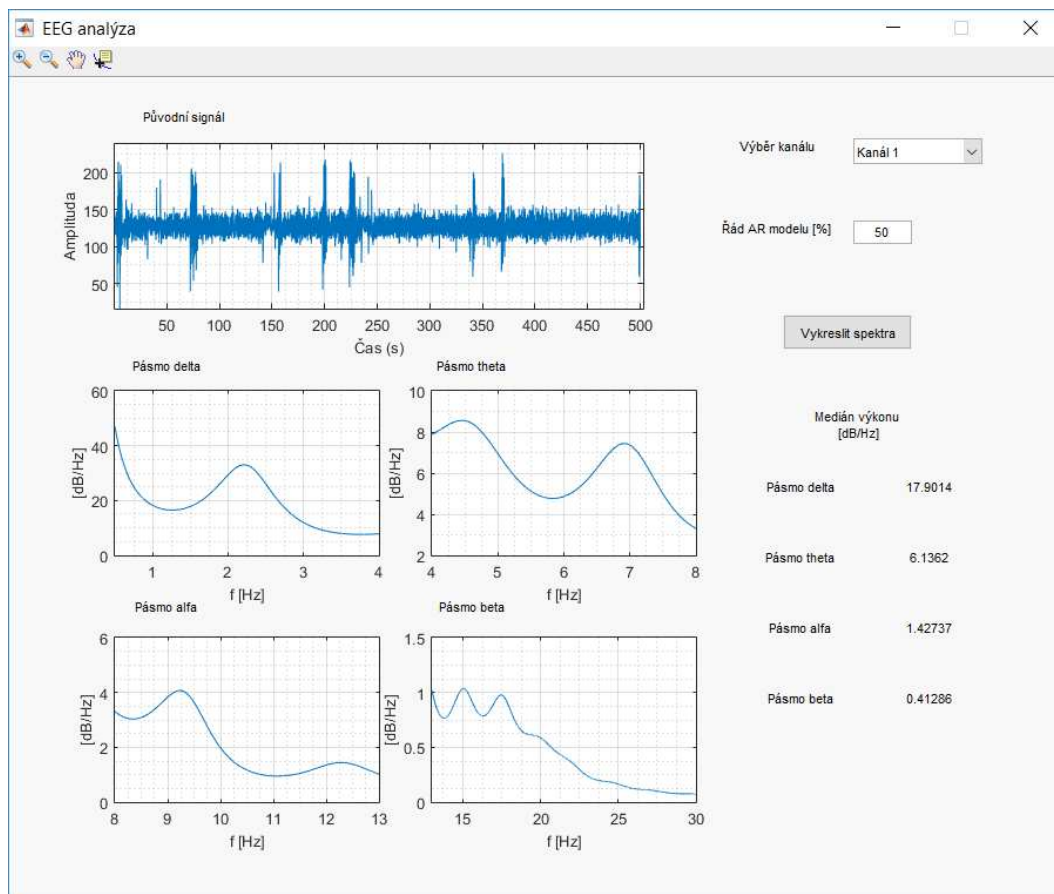
3.8.3. Analýza EEG

Analýza EEG je i v současnosti velmi složitá, protože v hodnocení časového průběhu signálu se značně projevuje subjektivita a zkušenosti lékaře, jelikož je signál náhodný a nelze jej nijak univerzálně popsat. Signál EEG se skládá ze 4 základních frekvenčních pásem (alfa, beta, théta a delta), z nichž každé je typické pro určitou abnormalitu či momentální rozpoložení pacienta (případně spánek apod.). Modul aplikace pro analýzu EEG obsahuje výpočet aproximovaného frekvenčního spektra (autoregresní model vypočtený kovarianční metodou – funkce *pcov*) právě v těchto pásmech a v každém z nich počítá medián hustoty výkonu spektra. Rozmezí pásem bylo zvoleno následovně:

Tabulka 5: Rozsahy pásem použité při analýze EEG.

Pásmo	Rozsah
Delta	0,5 – 4 Hz
Théta	4 – 8 Hz
Alfa	8 – 13 Hz
Beta	13 – 30 Hz

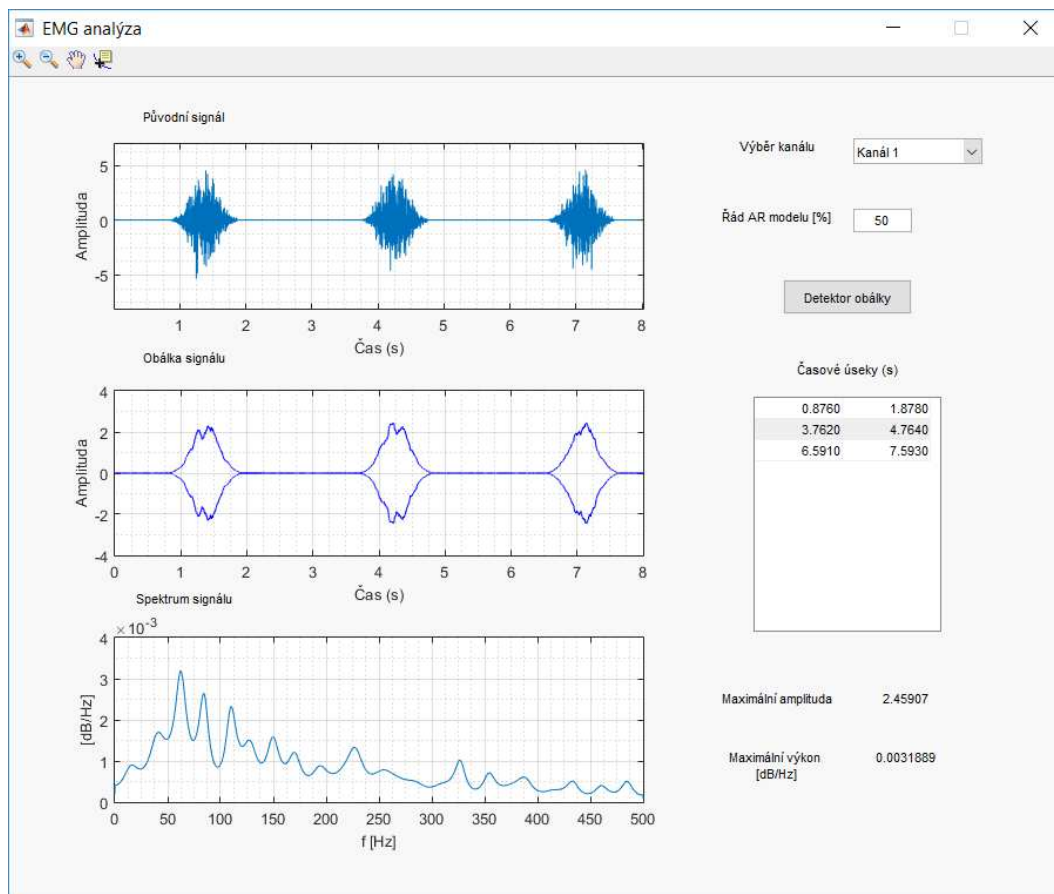
Tímto způsobem lze zjistit, zda není výkon v některých pásmech redukovaný či naopak neobvykle výrazný.



Obrázek 65: Příklad modulu analýzy EEG.

3.8.4. Analýza EMG

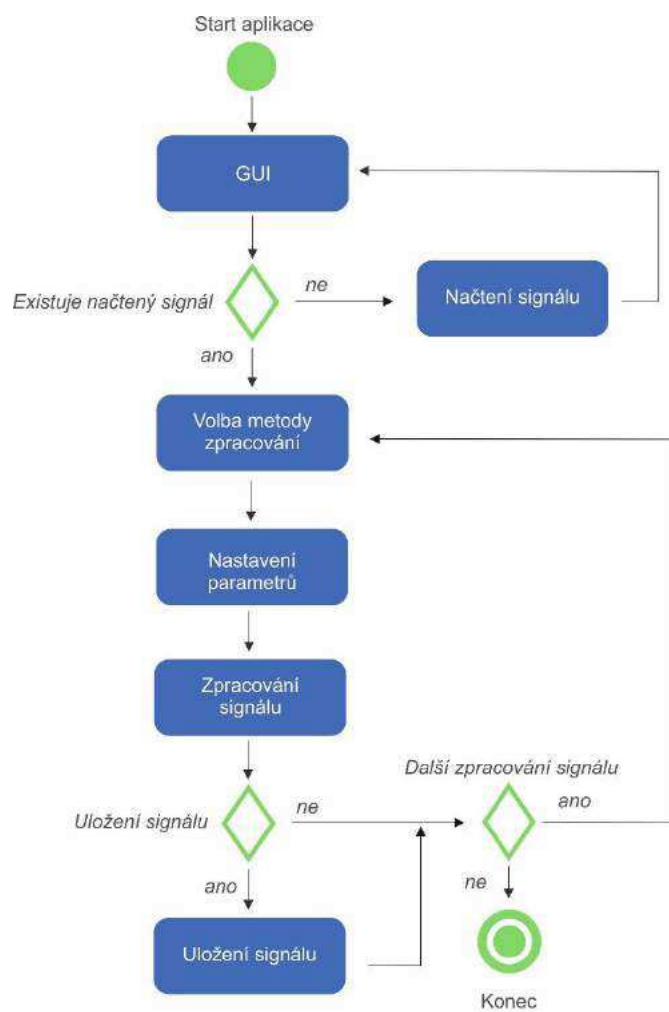
Jelikož je EMG nestacionární náhodný signál, jeho analýza je velmi náročná. Existují dekompoziční techniky k získání potenciálu konkrétního svalového vlákna, avšak aplikace pracuje s mnohem jednodušším procesem. Počítá obálku signálu a z této obálky vyhodnocuje délku trvání každé svalové aktivity zvlášť (kdy signál není nulový). Obálka je počítána pomocí Hilbertovy transformace (funkce *Hilbert*), následně je spočtena absolutní hodnota a vyhlazená funkcí *smooth*. Tento postup lze využít u monitorování životních funkcí, kdy je takto zaznamenán každý pohyb pacienta. Pro přehled výkonu signálu je vykresleno aproximované frekvenční spektrum obdobně jako u EEG a vypočten maximální výkon spolu s maximální amplitudou obálky v časové oblasti.




Obrázek 66: Příklad modulu analýzy EMG.

3.9. Ukázka implementace do jazyka C#

Jelikož firma Certicon je firmou fungující na platformě .NetFramework, byla vytvořena ukázka programu v jazyce C#. Vzhledem k tomu, že implementace některých složitějších algoritmů by byla do tohoto jazyka velmi náročná, byla naprogramována aplikace pouze pro základní metody filtrace signálu, jejichž výsledky lze srovnat s výsledky zpracování v Matlabu. Aplikace umožňuje načtení jednoho nebo více signálů ve formátu .csv, zpracování, vykreslení původního a upraveného signálu a uložení upraveného signálu opět ve formátu .csv. Pro zpracování byl naimplementován FIR filtr, pracující se zadanými koeficienty (přednastavený filtr je typu DP řádu 150 o mezní frekvenci 30 Hz), IIR filtr s parametrem mezní frekvence (přednastavený filtr je Buttherworthův filtr typu DP řádu 10 o mezní frekvenci 50 Hz) a klouzavý průměr s nastavitelnou délkou okna (přednastaveno je okno o délce 5 vzorků). Každá tato filtrační metoda je implementována v samostatné aktivitě, čímž je zajištěna modularita softwaru.



Obrázek 67: : UML diagram aplikace v C#




Obrázek 68: GUI aplikace v C#.

Všechny tři implementované metody zpracování signálu byly srovnány se zpracováním v Matlabu. Pro otestování byl v LabView nasimulován signál EKG s přidaným rušením. Parametry tohoto signálu jsou shrnuty níže (viz Tabulka 6).

Tabulka 6: Parametry simulovaného EKG pro zpracování v C#.

Maximální amplituda	Minimální amplituda	Tepová frekvence	Dechová frekvence	STD tepové frekvence
1,2 mV	-0,4 mV	60 bpm	15 bpm	1 bpm
Vzorkovací frekvence	Délka záznamu	Bílý šum	Síťové rušení	SNR
512 Hz	10 s	0,5 mV	0,1 mV / 50 Hz	1,025 dB



Obrázek 69: Generovaný signál EKG s přidaným šumem.


Pro všechny implementované metody filtrace do jazyka C# byly vypočítány korelační koeficienty vůči původně generovanému signálu EKG, směrodatná odchylka (SD, Standard Deviation) a SNR, vycházejícího ze vztahu (1.1), kde výkon signálu je reprezentován výkonem signálu po filtraci a výkon šumu je určen jako rozdíl mezi výkonem signálu po filtraci a výkonem generovaného signálu bez přidaného šumu. Dalším krokem analýzy je Blandův-Altmanův graf (dále B-A graf), který zobrazuje vztah mezi výsledkem filtrace signálu a původním signálem.

Blandova-Altmanova analýza srovnává dvě proměnné co do jejich rozdílu a průměru, jež se počítají v každém jejich vzorku. Výsledný graf je pak závislostí mezi tímto rozdílem a průměrem. Je určena

střední hodnota (*AVG*) a směrodatná odchylka (*SD*) rozdílu, jejichž hodnoty jsou zobrazeny v grafu jako vodorovné přímky (plná přímka odpovídá hodnotě *AVG* a pozice čerchovaných přímek jsou určeny jako $AVG \pm 1,96 \cdot SD$).

Tabulka 7: Výsledky implementace IIR filtru.


	Matlab	C#
Korelační koeficient	0,113	0,801
SNR [dB]	-0,0881	5,89
SD	0,268	0,251



Obrázek 70: B-A grafy IIR filtrace vůči původnímu signálu EKG.

Tabulka 8: Výsledky implementace FIR filtru.


	Matlab	C#
Korelační koeficient	0,0224	0,553
SNR [dB]	-0,521	2,81
SD	0,265	0,207



Obrázek 71: B-A grafy FIR filtrace vůči původnímu signálu EKG.

Tabulka 9: Výsledky implementace klouzavého průměru.

	Matlab	C#
Korelační koeficient	0,537	0,552
SNR [dB]	2,509	2,81
SD	0,201	0,206



Obrázek 72: B-A grafy filtrace klouzavým průměrem vůči původnímu signálu EKG.

Na výsledcích porovnání způsobů implementace filtračních metod je znát, že filtrace v C# je mnohem přesnější při porovnání s původním signálem – korelační koeficienty i SNR jsou ve všech případech vyšší. Nejsrovnatelnějších hodnot sledovaných parametrů dosáhla metoda klouzavého průměru, kdy se hodnoty korelačních koeficientů a SNR lišily maximálně pouze v desetínách.

Největšího zlepšení v SNR (o 4,8 dB) a zachování korelace (0,801) dosáhla metoda IIR filtrace v C#. Markantní rozdíly u zpracování v Matlabu mohou být následkem znatelnějšího zpoždění signálu po filtraci. Při srovnání metod zpracování v C# je nejpřesnější metodou IIR filtrace, dále FIR filtrace (filtrace klouzavým průměrem je v tomto případě srovnatelná s filtrací Hammingovým oknem), což odpovídá výsledkům testování v Matlabu, které jsou zpracovány níže.

4. Experimentální porovnání metod zpracování signálu

Pro otestování správné funkce implementovaných metod v Matlabu bylo provedeno experimentální ověření výsledků jednotlivých metod zpracování, a to jak na syntetických, tak na reálných datech. Srovnávat lze jak odstraňování stejných typů rušení na různých signálech různými metodami, tak použití stejných metod k odstranění různých druhů šumu a stejně tak i rozdíly v parametrech jednotlivých metod. Volba jednotlivých metod a nastavení jejich parametrů bylo inspirováno rešerší současné literatury (viz kapitoly 1.1.4, 1.2.4, 1.1.3, 1.2.4 a 1.3.4).

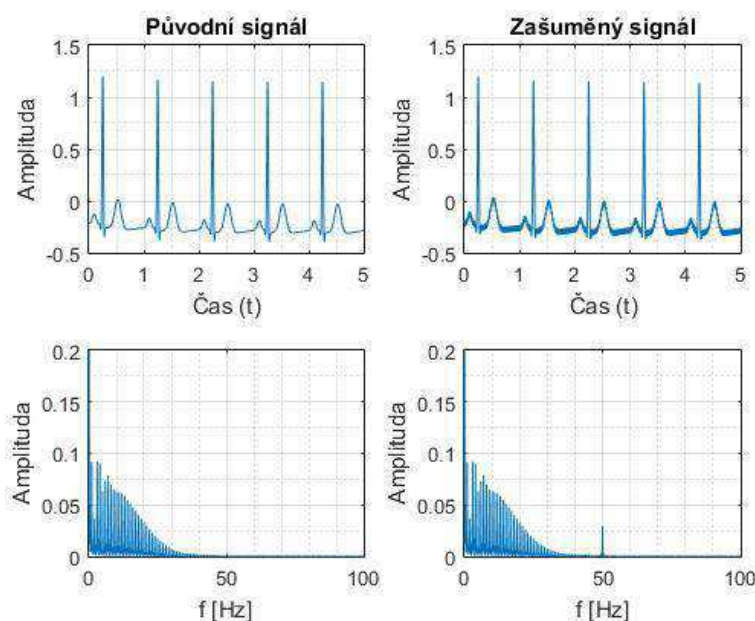
4.1. Odstranění síťového rušení

Síťové rušení je nejvhodnějším způsobem, jak ověřit filtrační metody na všech zkoumaných typech biologických signálů, jelikož lze k jeho odstranění použít velkou škálu metod. Pro porovnání výsledků těchto metod byla vytvořena ideální křivka EKG (viz Tabulka 10), syntetický záznam EEG (viz Tabulka 11) a syntetický záznam EMG (Tabulka 12) generátorem biologických signálů v programu LabView. Signály PPG a FKG v takovéto syntetické podobě nebyly k dispozici, proto jsou metody otestovány na reálných datech.

Ke generovanému signálu EKG bylo přidáno síťové rušení o frekvenci 50 Hz a amplitudě 0,03 mV. Hodnota SNR takto zarušeného signálu je 22,9 dB.

Tabulka 10: Parametry generované EKG křivky pro zpracování v Matlabu.

Maximální amplituda	Minimální amplituda	Tepová frekvence	Vzorkovací frekvence	Délka záznamu	SD
1,2 mV	-0,4 mV	60 bpm	512 Hz	10 s	0,2049

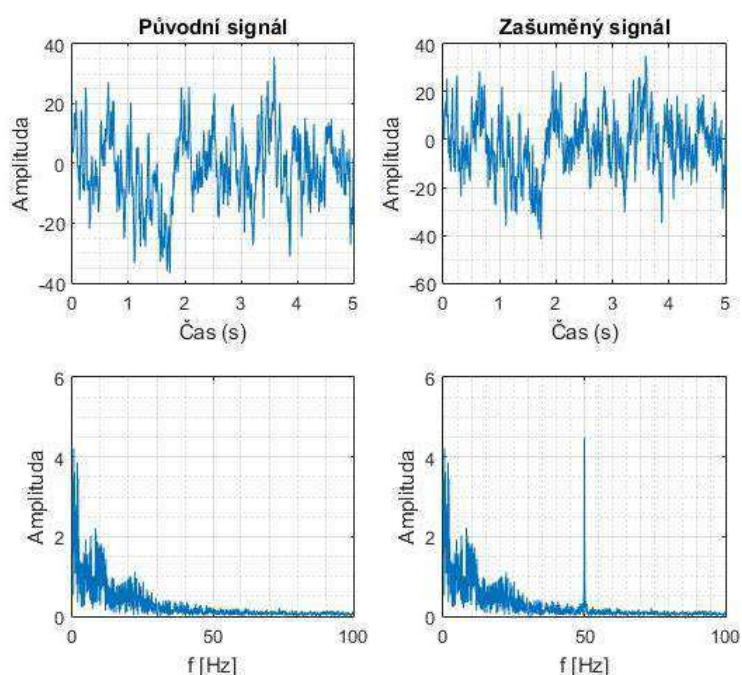


Obrázek 73: Původní EKG a EKG s přidáním šumu v časové a frekvenční oblasti.

Ke generovanému signálu EEG je přičteno rušení o frekvenci 50 Hz a amplitudě 5 μV , přičemž SNR je 11,02 dB.

Tabulka 11: Parametry generovaného EEG signálu pro zpracování v Matlabu.

Maximální amplituda	Vzorkovací frekvence	Délka záznamu	Výkon ve frekvenčních pásmech				
			Delta	Théta	Alfa	Beta	SD
100 μV	256 Hz	10 s	0,69	0	0,21	0,1	11,99

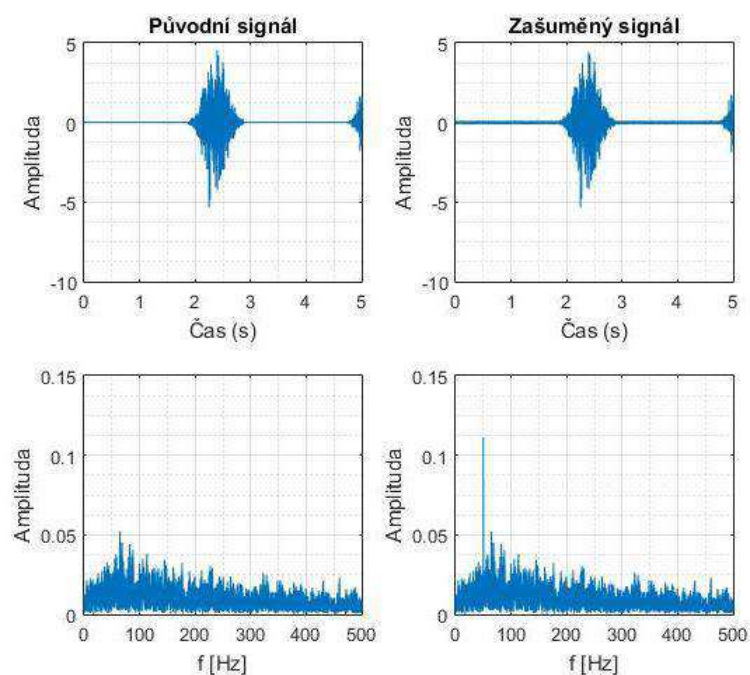


Obrázek 74: Původní EEG a EEG s přidaným šumem v časové a frekvenční oblasti.

Ke generovanému signálu EMG bylo přidáno rušení o frekvenci 50 Hz a amplitudě 0,1 mV. Hodnota SNR zarušeného signálu je 18,6 dB.


Tabulka 12: Parametry generovaného EMG signálu pro zpracování v Matlabu.

Maximální amplituda	Délka kontrakce	Frekvenční rozsah	Spektrální výkon	Vzorkovací frekvence	Délka záznamu	SD
4 mV	1 s	20 – 300 Hz	0,8 / 70 Hz	512 Hz	10 s	0,595



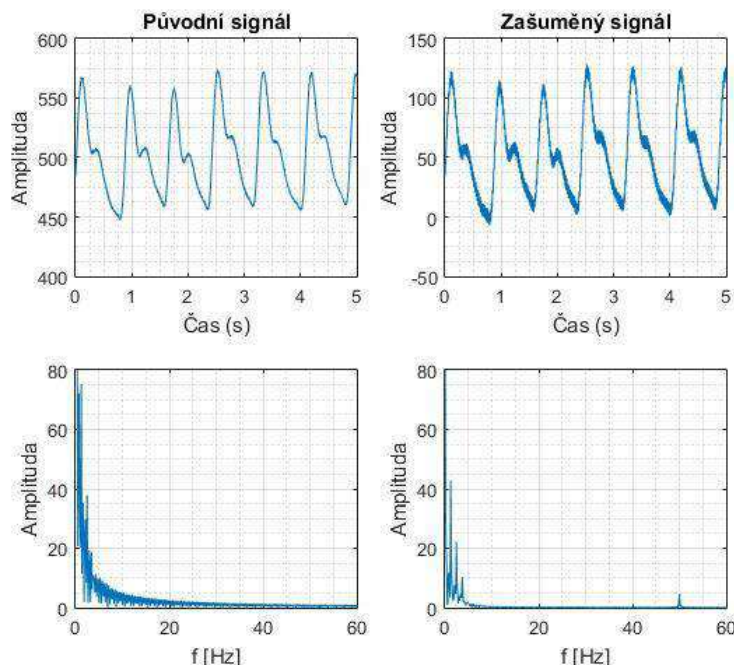
Obrázek 75: Původní EMG a EMG s přidaným šumem v časové a frekvenční oblasti.

K signálu FKG, ze kterého byl vybrán 10 sekundový záznam a je navzorkován s frekvencí 2 kHz, bylo přidáno rušení o frekvenci 50 Hz a amplitudě 400 mV. Takto získaný signál má SNR 8,27 dB. SD původního signálu je 683.



Obrázek 76: Původní FKG a FKG s přidaným šumem v časové a frekvenční oblasti.

Pro zarušení PPG signálu bylo zvoleno rušení o frekvenci 50 Hz a amplitudě 5 mV. Signál je vzorkován frekvencí 500 Hz a délka jeho záznamu je 6 s. Hodnota SNR zašuměného signálu je -16,9 dB a SD je 33,8.



Obrázek 77: Původní PPG a PPG s přidaným šumem v časové a frekvenční oblasti.

Pro porovnání jednotlivých filtračních metod byl každý výše popsany signál filtrován FIR filtrem všemi typy oken, všemi typy IIR filtru včetně notch filtru, klouzavým průměrem a ANC filtrem. Pro srovnání účinnosti byla otestována i WT v několika verzích.

4.1.1. FIR filtrace

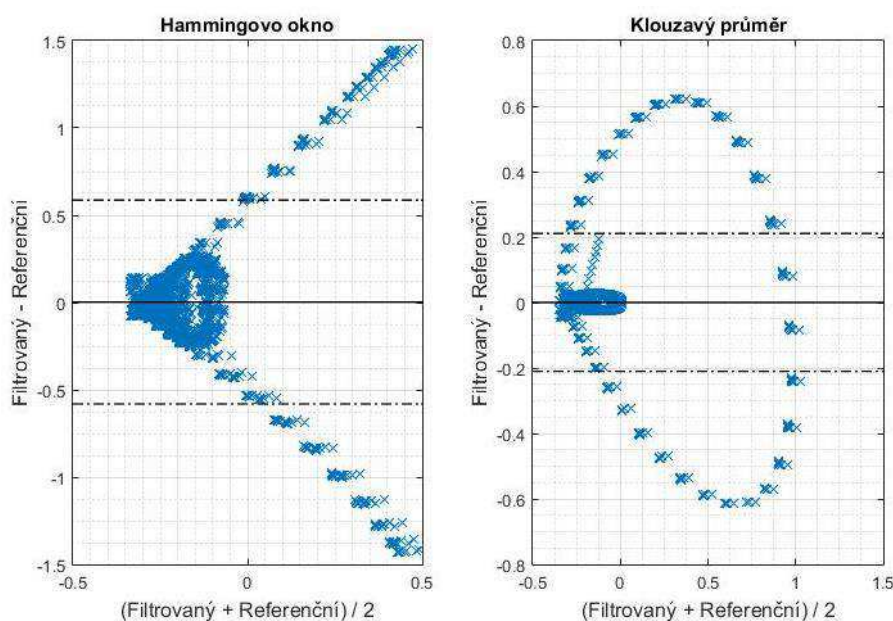
Pro všechny typy oken FIR filtru byl navrhnut filtr typu PZ řádu 100 s mezními frekvencemi 49 a 51 Hz. Do této části je zařazen také klouzavý průměr (tzn. obdélníkové okno FIR filtru), který filtruje oknem velikosti 10.

Filtrace EKG

V případě FIR filtrace EKG signálu filtrovaný signál nevykazuje téměř žádnou korelaci (viz Tabulka 13), kromě jediného případu, a to klouzavého průměru, kde je korelace relativně zachována, avšak ani klouzavý průměr nedosáhl vyšší hodnoty SNR než zašuměný signál a SD se po filtraci klouzavým průměrem liší nejvíce od původní hodnoty. Tyto výsledky mohou být způsobeny zpožděním signálu při filtraci, ale také silnou deformací tvaru křivky oproti křivce původní.

Tabulka 13: Srovnání výsledků FIR filtrace EKG.

Okno	Korelační koeficient	SNR [dB]	SD
Hamming	-0,0492	-0,1487	0,206
Blackman	-0,0496	-0,1488	0,206
Hanning	-0,0497	-0,1505	0,206
Bartlett	-0,0493	-0,149	0,206
Obdélníkové	0,855	8,47	0,192




Obrázek 78: Porovnání B-A grafů filtrace Hammingova okna a klouzavého průměru vůči původnímu EKG.

Filtrace EEG

Výsledky FIR filtrace signálu EEG (Tabulka 14) jsou podobné výsledkům filtrace EKG, opět nejvyšší korelace dosáhl sice klouzavý průměr, ale SNR nebylo zvýšeno oproti filtrovanému signálu, naopak je hodnota nižší. Rozdíl původního a filtrovaného signálu však mnohem méně přesahuje svou SD (viz Obrázek 79).

Tabulka 14: Srovnání výsledků FIR filtrace EEG.

Okno	Korelační koeficient	SNR [dB]	SD
Hamming	0,113	-2,38	12,1
Blackman	0,112	-2,36	12,1
Hanning	0,112	-2,37	12,1
Bartlett	0,112	-2,37	12,1
Obdélníkové	0,893	6,42	11,9



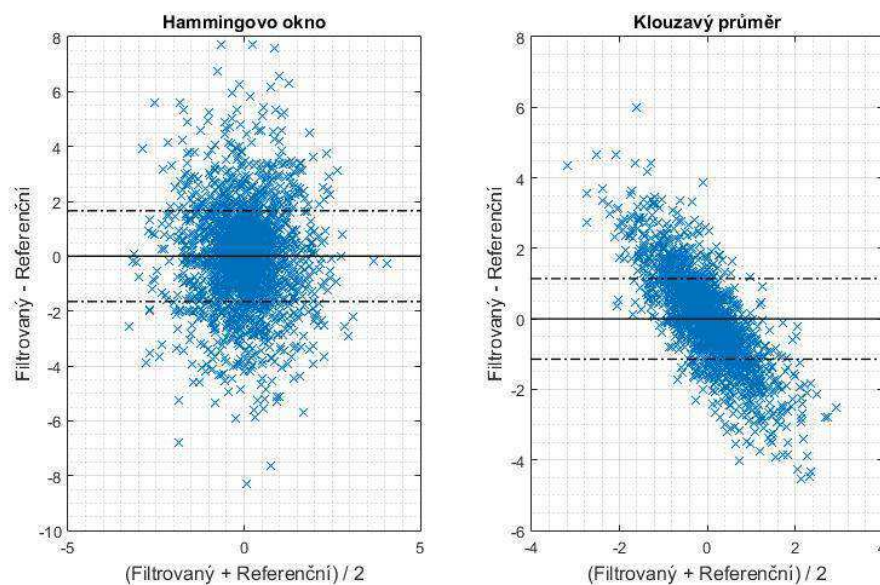
Obrázek 79: Porovnání B-A grafů filtrace Hamingova okna a klouzavého průměru vůči původnímu EEG.

Filtrace EMG

Při FIR filtraci EMG opět v žádném z použitých oken nedošlo ke zvýšení SNR a ani nebyla zachována korelace s původním signálem (viz Tabulka 15). Filtrace EMG frekvenčně selektivními filtry je obecně problémem, neboť zásadně zasahuje do širokého frekvenčního pásma signálu.

Tabulka 15: Srovnání výsledků FIR filtrace EMG.

Okno	Korelační koeficient	SNR [dB]	SD
Hamming	-0,0173	-3,13	0,587
Blackman	-0,0176	-3,14	0,588
Hanning	-0,0178	-3,14	0,588
Bartlett	-0,0176	-3,12	0,590
Obdélníkové	0,241	-8,49	0,219




Obrázek 80: Porovnání B-A grafů filtrace Hamingova okna a klouzavého průměru vůči původnímu EMG.

Filtrace FKG

Při FIR filtraci FKG byla zachována relativně vysoká korelace s původním signálem opět při použití klouzavého průměru, avšak i v tomto případě došlo ke snížení SNR vůči filtrovanému signálu a vyskytla se nejvyšší odchylka ve výpočtu SD (viz Tabulka 16).

Tabulka 16: Srovnání výsledků FIR filtrace FKG.

Okno	Korelační koeficient	SNR [dB]	SD
Hamming	-0.183	-3.55	713
Blackman	-0.181	-3.54	715
Hanning	-0.182	-3.56	712
Bartlett	-0.182	-3.53	717
Obdélníkové	0.787	3.69	681




Obrázek 81: Porovnání B-A grafů filtrace Hamingova okna a klouzavého průměru vůči původnímu FKG.

Filtrace PPG

Filtrace PPG FIR filtrem nemá za následek stejně razantní snížení korelace ani SNR jako u ostatních signálů (nejspíš z důvodu svého velmi úzkého frekvenčního spektra), avšak v nejlepším případě (klouzavý průměr) zůstala hodnota SNR stejná (viz Tabulka 17).

Tabulka 17: Srovnání výsledků FIR filtrace PPG.

Okno	Korelační koeficient	SNR [dB]	SD
Hamming	0,443	-17,1	34,5
Blackman	0,443	-17,1	34,6
Hanning	0,443	-17,1	34,6
Bartlett	0,443	-17,1	34,56
Obdélníkové	0,993	-16,9	33,8



Obrázek 82: Porovnání B-A grafů filtrace Hamingova okna a klouzavého průměru vůči původnímu PPG.

4.1.2. IIR filtrace


Parametry implementovaných typů IIR filtru jsou nastaveny následovně: PZ řádu 5, mezní frekvence 49 a 51 Hz, dovolené zvlnění v propustném pásmu 5 dB a v nepropustném pásmu 30 dB. V případě notch filtru je řád také 5, mezní frekvence pak přesně 50 Hz.

Filtrace EKG

Výsledky IIR filtrace signálu EKG pozitivně zlepšují SNR i zachovávají korelaci s původním signálem. Korelační koeficient neklesá pod 0,996 a SNR se zlepšuje v závislosti na použité metodě zhruba od 6 až 10 dB. Výpočet v SD je také zanedbatelně odlišný od SD původního signálu (viz Tabulka 18). Nejnížší hodnoty SNR dosáhl Čebyševův filtr 1 a nejvyšší pak Butterworthův filtr.

Tabulka 18: Srovnání výsledků IIR filtrace EKG.

Filtr	Korelační koeficient	SNR [dB]	SD
Butterworth	0,999	32,0	0,2049
Čebyšev 1	0,996	24,4	0,2043
Čebyšev 2	0,999	32,6	0,2049
Eliptický	0,998	29,5	0,2047
Notch	0,998	28,9	0,2047




Obrázek 83: B-A graf IIR filtrace (notch) vůči původnímu EKG.

Filtrace EEG

V případě IIR filtrace EEG signálu se výsledky příliš neliší od filtrace signálu EKG. Nejvyššího SNR dosáhla metoda notch filtru a nejnižší hodnoty Čebyševův filtr 1. typu (Tabulka 19). SNR se zvýšilo téměř o 10 dB.

Tabulka 19: Srovnání výsledků IIR filtrace EEG.

Filtr	Korelační koeficient	SNR [dB]	SD
Butterworth	0,995	20,01	11,9
Čebyšev 1	0,989	16,6	11,9
Čebyšev 2	0,996	20,6	11,9
Eliptický	0,995	19,9	11,9
Notch	0,996	20,6	11,9




Obrázek 84: B-A graf IIR filtrace (notch) vůči původnímu EEG.

Filtrace EMG

Filtrace EMG potvrdila skutečnost, že filtrace síťového rušení, které se vyskytuje uvnitř frekvenčního spektra EMG je složitější než u ostatních signálů a frekvenčně selektivní filtrace není příliš vhodnou metodou (viz Tabulka 20). Hodnota SNR se v tomto testu nezlepšila v žádné z metod IIR filtrace, avšak hodnota korelace se příliš nezměnila (s výjimkou filtru Čebyševova typu, kde byl zaznamenán vysoký pokles SNR).

Tabulka 20: Srovnání výsledků IIR filtrace EMG.

Filtr	Korelační koeficient	SNR [dB]	SD
Butterworth	0,969	12,1	0,593
Čebyšev 1	0,556	-3,48	0,331
Čebyšev 2	0,972	12,6	0,592
Eliptický	0,968	11,8	0,581
Notch	0,968	11,8	0,576




Obrázek 85: B-A graf IIR filtrace (notch) vůči původnímu EMG.

Filtrace FKG

Pro filtraci síťového rušení v signálu FKG se metoda IIR filtrace ukázala jako vhodná, avšak ne s tak dobrými výsledky jako v případě EKG nebo EEG (viz Tabulka 21). Ke zlepšení SNR nedošlo pouze v případě použití notch filtru, v ostatních případech se hodnota SNR zvedla průměrně o 6 dB.

Tabulka 21: Srovnání výsledků IIR filtrace FKG.

Filtr	Korelační koeficient	SNR [dB]	SD
Butterworth	0,985	15,2	674
Čebyšev 1	0,988	16,2	676
Čebyšev 2	0,979	13,8	649
Eliptický	0,988	16,2	676
Notch	0,937	8,58	640




Obrázek 86: B-A graf IIR filtrace (notch) vůči původnímu FKG.

Filtrace PPG

Filtrace PPG IIR filtrem je co do hodnoty SNR srovnatelná s FIR filtrace, avšak na rozdíl od FIR filtrace je zachována korelace mnohem více. Použitím IIR filtrace se SNR nezlepšilo, ale ani výrazně nezhoršilo (viz Tabulka 22).

Tabulka 22: Srovnání výsledků IIR filtrace PPG.

Filtr	Korelační koeficient	SNR [dB]	SD
Butterworth	0,999	-16,9	33,8
Čebyšev 1	0,999	-16,9	33,8
Čebyšev 2	0,999	-16,97	33,8
Eliptický	0,999	-16,97	33,8
Notch	0,999	-16,97	33,8



Obrázek 87: B-A graf IIR filtrace (notch) vůči původnímu PPG.

4.1.3. ANC filtrace


K ANC filtraci byl využit referenční signál sinusového průběhu o amplitudě 1 a frekvenci 50 Hz. Řád filtrace byl nastaven na hodnotu 1, jelikož filtrace tak dosahovala nejvyššího výsledku SNR.

Filtrace EKG

Při použití ANC filtru došlo k výrazně přesnému odstranění šumu – korelace se blíží 1 a SNR se zvýšilo o 13 dB (viz Tabulka 23).

Tabulka 23: Filtrace ANC signálu EKG.

Filtr	Korelační koeficient	SNR [dB]	SD
ANC	0,999	35,6	0,205




Obrázek 88: B-A graf ANC filtrace vůči původnímu EKG.

Filtrace EEG

I v případě ANC filtrace EEG došlo k výraznému zvýšení SNR (téměř o 16 dB) a zachování korelace (viz Tabulka 24).

Tabulka 24: Filtrace ANC signálu EEG.

Filtr	Korelační koeficient	SNR [dB]	SD
ANC	0,999	37,0	12,0




Obrázek 89: : B-A graf ANC filtrace vůči původnímu EEG.

Filtrace EMG

V případě filtrace signálu EMG metodou ANC došlo ke zvýšení SNR zhruba o 22 Db (viz Tabulka 25), což je doposud nejvyšší hodnota zlepšení SNR z testovaných metod. Jelikož se ostatní zde testované metody neprojevily jako vhodný adept na filtraci síťového rušení EMG, zůstává tak ANC jedinou vhodnou metodou.

Tabulka 25: Filtrace ANC signálu EMG.

Filtr	Korelační koeficient	SNR [dB]	SD
ANC	0,999	40,2	0,595




Obrázek 90: : B-A graf ANC filtrace vůči původnímu EMG.

Filtrace FKG

I v případě signálu FKG se ANC filtrace projevila jako velice příznivou metodou – korelace se opět blíží k 1 a SNR se zlepšilo o 20 dB (viz Tabulka 26).

Tabulka 26: Filtrace ANC signálu FKG.

Filtr	Korelační koeficient	SNR [dB]	SD
ANC	0,999	28,8	683




Obrázek 91: : B-A graf ANC filtrace vůči původnímu FKG.

Filtrace PPG

Na rozdíl od ostatních signálů, při použití ANC k filtraci PPG signálu nedošlo ke změně SNR, korelace se však nezměnila (viz Tabulka 27).

Tabulka 27: Filtrace ANC signálu PPG.

Filtr	Korelační koeficient	SNR [dB]	SD
ANC	0,999	-16,9	33,9



Obrázek 92: : B-A graf ANC filtrace vůči původnímu PPG.

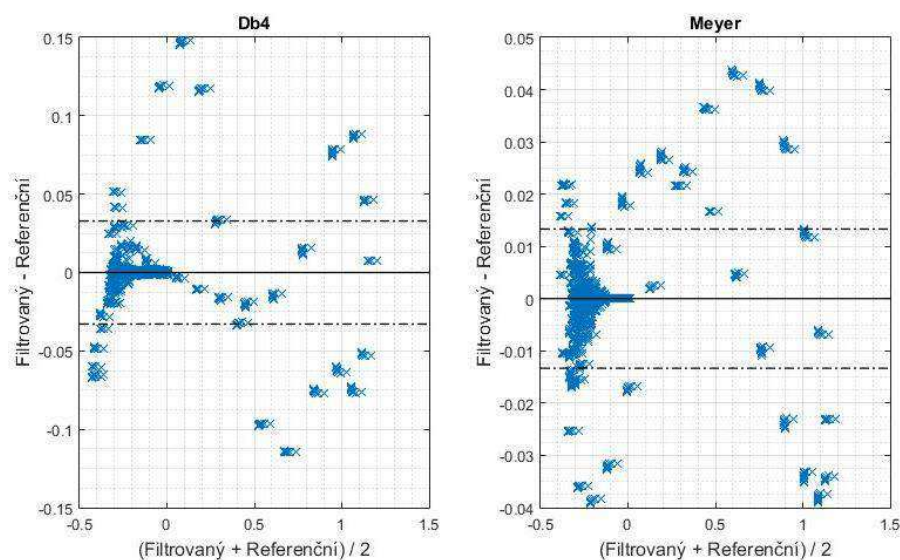
4.1.4. WT

Filtrace EKG

Pro WT byla využita v případě EKG vlnka Daubechies šířky 4, Meyerova vlnka, Coifletova vlnka šířky 5 a úroveň rozkladu 3. Při použití všech těchto typů vlnek došlo ke zvýšení SNR při zachování vysoké korelace, nejvyšší hodnoty však dosáhla vlnka Meyerova, a to o 10 dB více než původní signál (viz Tabulka 28).

Tabulka 28: WT signálu EKG.

Vlnka	Korelační koeficient	SNR [dB]	SD
Db4	0,996	24,9	0,204
Meyerova	0,999	32,7	0,205
Coif5	0,998	28,8	0,205




Obrázek 93: Porovnání B-A grafů jednotlivých typů vlnek WT vůči původnímu EKG.

Filtrace EEG

V případě EEG byla použita vlnka Daubechies šířky 10, Meyerova vlnka a Coifletova vlnka šířky 4. Level rozkladu byl v obou případech nastaven na hodnotu 2. Ve všech typech WT došlo ke zvýšení SNR maximálně o 3 dB a korelace byla snížena (viz Tabulka 29).

Tabulka 29: WT signálu EEG.

Vlnka	Korelační koeficient	SNR [dB]	SD
Db10	0,981	14,4	11,7
Meyerova	0,981	14,4	11,7
Coif4	0,981	14,2	11,7




Obrázek 94: B-A graf WT (Meyerova vlnka) vůči původnímu EEG.

Filtrace EMG

Pro filtraci signálu EMG byla pro ukázkou zvolena vlnka Daubechies šířky 2 a Coifletova vlnka šířky 3 při úrovni rozkladu 4. Ve všech případech WT byla hodnota SNR snížena do záporných hodnot a filtrovaný signál nevykazuje vysokou korelaci se signálem původním (viz Tabulka 30). Odchylka v tomto případě nastává také při výpočtu SD (zhruba o 0,45). Metoda WT tedy není vhodná k filtraci síťového rušení v signálu EMG.

Tabulka 30: WT signálu EMG.

Vlnka	Korelační koeficient	SNR [dB]	SD
Coif3	0,245	-11,9	0,146
Db2	0,241	-12,0	0,144




Obrázek 95: B-A graf WT (vlnka Db2) vůči původnímu EMG.

Filtrace FKG

Signál FKG byl zpracován WT s použitím Meyerovy vlnky a Symletovy vlnky šířky 10, v obou případech při úrovni rozkladu 5. Korelace spolu se SNR byla ve všech testovaných typech metody snížena (viz Tabulka 31). Liší se i SD původního a filtrovaného signálu.

Tabulka 31: WT signálu FKG.

Vlnka	Korelační koeficient	SNR [dB]	SD
Meyer	0,716	0,242	489
Sym10	0,737	0,764	503




Obrázek 96: B-A graf WT (vlnka Sym10) vůči původnímu FKG.

Filtrace PPG

Pro filtraci PPG signálu byly zvoleny vlnky Coifletova šířky 2, Daubechies šířky 11 a Symletova šířky 6. Ve všech případech byl nastaven level rozkladu na hodnotu 6. Korelace signálů byla zachována na velmi vysoké hodnotě, avšak hodnota SNR se opět nezlepšila (viz Tabulka 32), tak jako ve většině případů filtrace PPG.

Tabulka 32: WT signálu PPG.

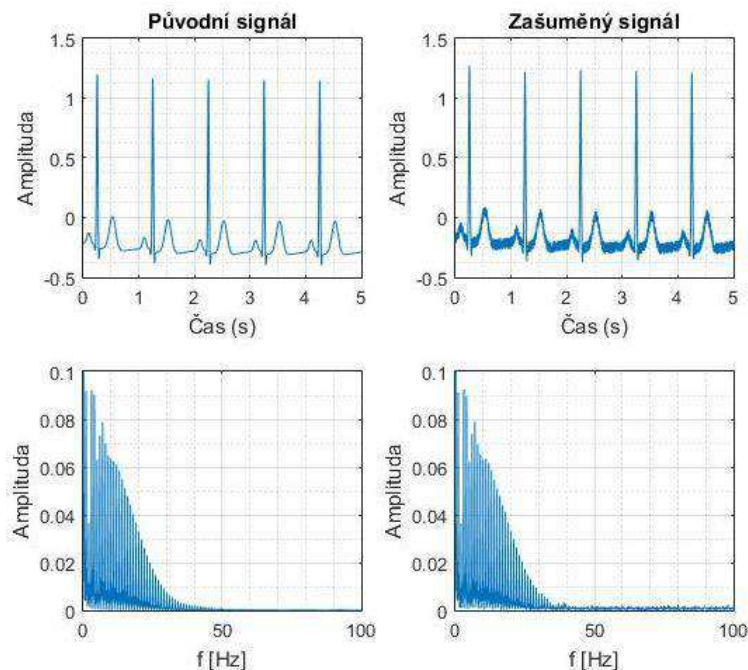
Vlnka	Korelační koeficient	SNR [dB]	SD
Coif2	0,999	-16,9	33,8
Db11	0,999	-16,9	33,8
Sym6	0,999	-16,9	33,8



Obrázek 97: B-A graf WT (vlnka Sym6) vůči původnímu PPG.

4.2. Odstranění náhodného šumu

Jak bylo již zmíněno, náhodný šum je velmi těžko odstranitelný především proto, že se vyskytuje na širokém frekvenčním rozsahu a nelze jej tak samostatně od signálu oddělit. Kapitola uvádí ukázkou filtrace náhodného šumu, přidaného po celé délce generovaného signálu EKG v LabView (viz kapitola 4.1). K signálu EKG byl přidán náhodný šum o amplitudě 0,1 mV (viz Obrázek 98). Takto zarušený signál má hodnotu SNR 13,17.



Obrázek 98: Syntetické EKG zarušené náhodným šumem.

Pro srovnání jsou uvedeny výsledky těch metod (viz Tabulka 33), které se významněji lišily v některém sledovaném parametru (např. v rámci FIR filtrace nebyl zaznamenán výrazný rozdíl mezi metodami, proto je uveden jako příklad filtr aproximovaný Hammingovým oknem).

Tabulka 33: Srovnání metod filtrace náhodného šumu v signálu EKG.

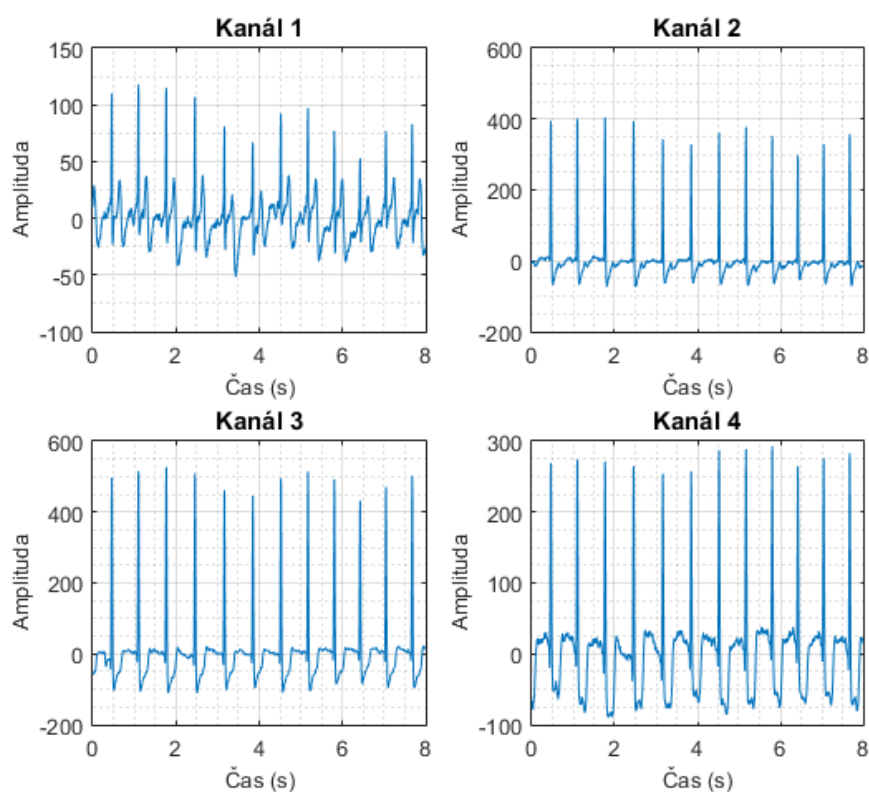
Typ filtrace	Korelační koeficient	SNR [dB]	SD
FIR Hamming	-0,0503	-1,31	0,206
IIR Butterworth	0,978	11,9	0,201
IIR Čebyšev 1	0,127	-1,05	0,194
IIR Čebyšev 2	0,967	11,1	0,205
IIR eliptický	0,976	9,18	0,186
Klouzavý průměr	0,962	8,50	0,185
WT Coif5	0,997	14,0	0,205
WT Db4	0,995	13,7	0,204
WT Meyer	0,998	14,1	0,205

Nevýhoda odstraňování náhodného šumu je jak v jeho frekvenčním rozsahu, tak v neznalosti jeho průběhu a vlastností, které by k výběru metody filtrace významně přispěly. Na uvedených výsledcích je vidět, že FIR filtrace se opět neprojevila jako příliš vhodnou metodou k odstraňování šumu v EKG. Naopak nejvyššího SNR dosáhla metoda Butterworthova IIR filtru, která je doposud nejpoužívanější metodou k filtraci typu DP. Pro srovnání je uveden výsledek filtrace Čebyševovým filtrem, který se neukázal jako vhodnou metodou k filtraci EKG. Nejvyšších hodnot SNR i korelace s původním signálem dosáhla metoda WT.

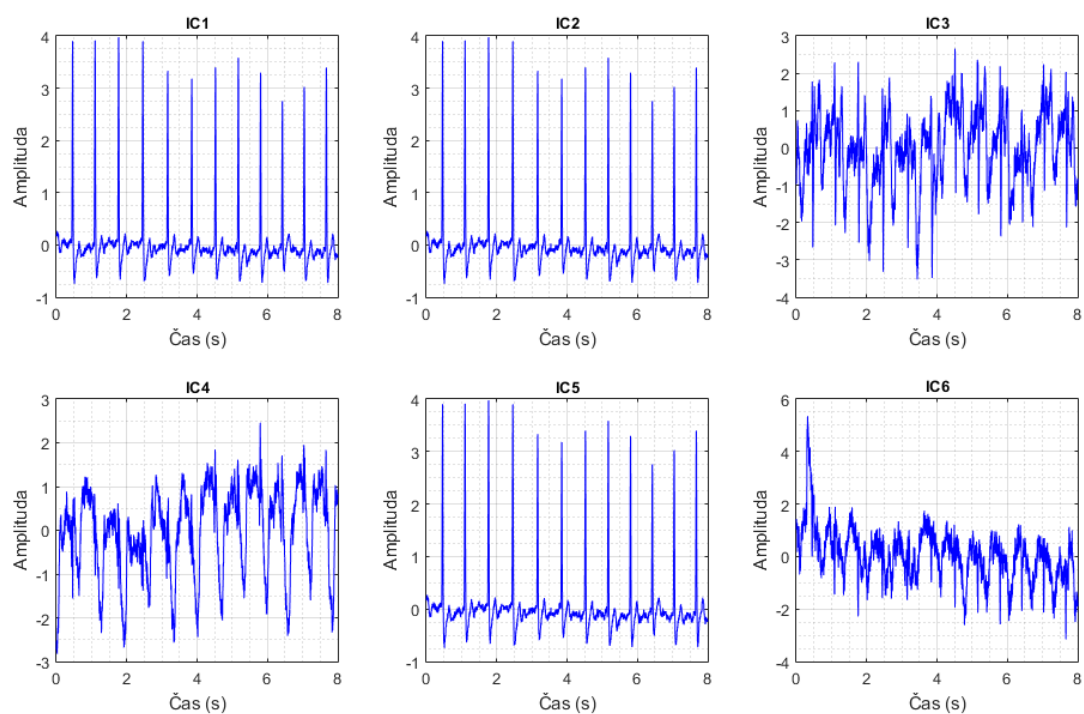
4.3. Odstranění artefaktů

V biologických signálech se často vyskytují artefakty, které nelze dostatečně přesně odstranit pomocí filtračních metod. Jedná se např. o pohybové artefakty při měření při pohybu (EKG, PPG) či artefakty jiných biologických potenciálů v signálu (např. artefakt EOG v záznamu EEG). Tyto nežádoucí úseky v signálu nemají většinou známý průběh ani frekvenční charakteristiku. Níže je ukázka takovýchto artefaktů, které lze detekovat např. metodou PCA nebo ICA.

Na EKG signál, zarušený pohybovými artefakty (měření probíhalo při cvičení) lze aplikovat metodu ICA pro získání nosného signálu a artefaktů. Podmínkou je měření EKG ve více kanálech. Pro ukázkou byl rekonstruován signál z databáze Physiobank (viz Obrázek 99), obsahující 4 kanály a vzorkovaný frekvencí 500 Hz. Pro rekonstrukci signálu bylo vypočteno 9 nezávislých komponent, z nichž 5 je potenciálním originálním signálem (viz Obrázek 100).



Obrázek 99: EKG s pohybovými artefakty (4 kanály).




Obrázek 100: Vypočtené nezávislé komponenty pro EKG s pohybovými artefakty.

Nezávislá komponenta č. 2 (IC2) byla vybrána pro další zpracování a byla vypočtena korelace mezi touto komponentou a každým kanálem původního signálu. Podle výpočtu (Tabulka 34) lze nalezenou komponentu pokládat jako adekvátní alternativou k původně měřenému signálu, i když křivka nemá dostatečně „kvalitní“ tvar pro přesnou analýzu.


Tabulka 34: Korelační koeficienty nezávislé komponenty a EKG signálu.

	Kanál 1	Kanál 2	Kanál 3	Kanál 4
Korelační koeficient	0,729	0,970	0,891	0,709



Obrázek 101: B-A graf ICA metody a původního EKG s pohybovými artefakty.

Pro srovnání byl proveden také výpočet metodou PCA, ta však nedokázala najít adekvátní křivku původního signálu (viz Obrázek 102). Ukazuje se tak nevýhoda PCA v omezení počtu komponent – musí být menší než počet signálů v matici. Pokud by bylo k dispozici více kanálů signálu, snad by i metoda PCA dokázala zrekonstruovat tento signál.




Obrázek 102: Hlavní komponenty pro EKG s pohybovými artefakty.

4.4. Separace signálů

Separace jednotlivých signálů z jejich směsice je typické pro měření plodového EKG při povrchové metodě měření, tj. elektrodami na břiše matky. Běžně se k tomuto účelu používají metody PCA a ICA, které dokáží plodový signál ze směsice plodového a matčina signálu oddělit. Ukázka separace signálů byla provedena na syntetických i reálných datech.


4.4.1. Syntetická data

K otestování správné funkčnosti metod byl použit 5 kanálový uměle vytvořený záznam abdominálního EKG o vzorkovací frekvenci 1 kHz. Vypočteny byly pomocí metody PCA 2 hlavní komponenty a pomocí metody ICA 6 nezávislých komponent, z nichž byla vybrána vždy jedna komponenta reprezentující plodové EKG a dále zpracována.




Obrázek 103: Ukázka uměle generovaného záznamu abdominálního EKG.

Korelační koeficient mezi získanou nezávislou a hlavní komponentou je 0,962. V případě syntetických dat abdominálního EKG lze tedy potvrdit, že použité metody PCA a ICA jsou vhodně implementovány pro analýzu fEKG i jiných aplikací. Častým rozdílem mezi metodami bývá pak neshoda v amplitudě, jelikož nezávislé komponenty jsou vždy v amplitudě pozměněny (viz Obrázek 105).




Obrázek 104: Plodové EKG získané metodami PCA a ICA.



Obrázek 105: B-A graf ICA metody vůči PCA metodě při separaci fEKG.


4.4.2. Reálná data

Na reálném záznamu abdominálního EKG byly vyzkoušeny metody PCA, ICA a ANC filtrace. Pro výpočty byly použity 3 kanály abdominálního a 1 kanál invazivního EKG z databáze Physiobank (viz Obrázek 106). Pro detekci plodového EKG a EKG matky byly vypočteny 2 nezávislé komponenty. Pro získání druhého signálu fEKG bylo vypočteno 6 nezávislých komponent, z nichž byla jedna vybrána pro další analýzu. Druhý signál EKG matky byl získán filtrací abdominálního EKG filtrem ANC s použitím invazivního EKG jako referenčního signálu.




Obrázek 106: Příklad invazivního a abdominálního EKG.

Získaný signál metodou ICA sice neproказuje s původním signálem silnou korelaci (-0,110), avšak při optickém hodnocení křivky lze říci, že při dalším zpracování takto získaného signálu (potlačení rušení) by mohl vzniknout signál srovnatelný s invazivně naměřeným EKG a posloužit tak např. k detekci tepové frekvence plodu. Nízká korelace může být následkem markantního snížení amplitudy signálu po výpočtu. Při výpočtu metodou PCA byl získán signál mnohem více ztracený v rušení než metodou ICA (viz Obrázek 107).




Obrázek 107: Porovnání metod ICA a PCA s invazivním fEKG.




Obrázek 108: B-A graf metody ICA a invazivního fEKG.

Při výpočtu EKG matky byl původní výstup ANC filtru invertovaný, se získanou hlavní komponentou tedy neprokazoval téměř žádnou korelaci. Byla proto provedena jeho inverze a hodnota korelačního koeficientu se zvýšila na 0,859. Není sice zcela přesné srovnávat dva takto vypočtené signály, ale vzhledem k problematice dostupnost ideálních dat ke všem typům testování, je srovnání filtrace ANC v tomto případě přípustné – např. takto separovaný signál bude vhodný k základním analýzám jako je detekce tepové frekvence, i když neposkytuje úplnou informaci o tvaru EKG křivky.



Obrázek 109: EKG matky získané metodou PCA a ANC filtrací.



Obrázek 110: B-A graf metody PCA vůči ANC filtraci abdominálního EKG.

Závěr

Náplní diplomové práce bylo ucelit poznatky o zpracování jednorozměrných biologických signálů, jejich měření, výskytu rušení a artefaktů v signálech a vytvořit program pro komplexní zpracování a analýzu signálu tak, aby splňoval co nejuniverzálnější podmínky pro práci se signály. V programu Matlab byl vytvořen program nejpoužívanějších metod zpracování signálů, které jsou již v praxi běžně zavedeny. Pro testování těchto metod aplikace nabízí možnost simulování rušení, která lze k signálům přidávat. Aplikace podporuje jak zpracování jednokanálových záznamů, tak i vícekanálových a jejich ukládání do formátu *.mat* pro další analýzu.

Pro otestování funkce jednotlivých modulů byly provedeny experimentální pokusy filtrace síťového rušení na všech typech klasifikovaných signálů, filtrace náhodného šumu v signálu EKG a separace signálů z abdominálního EKG pomocí metod PCA, ICA a ANC. Výsledky odpovídají předpokladům známých z literatury a praxe – typy filtrace použité v závislosti na řešerši literatury dosahují vyšších hodnot SNR i korelace než metody ostatní a některé signály (např. EMG) jsou ke zpracování ve frekvenční oblasti náročnější.

Podle výsledků je software vhodný pro testování, kdy je třeba porovnat účinnost jednotlivých metod při přidávání rušení a následné úpravě signálu. K základním úpravám signálu je aplikace dostačující, jelikož umožňuje množství funkcí, jak dostatečně přesně zpracovat různé typy signálu. Na druhou stranu tím, že je vytvořený software omezen svou co nejobecnější funkcí, je stále spoustu možností, jak program rozšířit a vylepšit tak, aby umožňoval např. i složitější analýzy signálů, více druhů předzpracování apod.

Literatura

- [1] RANGAYYAN, Rangaraj M. Biomedical signal analysis. Second edition. Hoboken, New Jersey: John Wiley & Sons, 2015. ISBN 9780470911396.
- [2] BRUCE, Eugene N. Biomedical signal processing and signal modeling. New York: Wiley, c2001. ISBN 0471345407.
- [3] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7.
- [4] EKSLER, Václav. Analýza hlavních komponent v problematice separace naslepo. *Elektrorevue* [online]. 2005, (29) [cit. 2017-10-16]. Dostupné z: http://www.kiv.zcu.cz/studies/predmety/tps/SVM-PCA-ICA/Analyza_hl_komponent.pdf
- [5] ŠMÍD, Radislav. Úvod do vlnkové transformace [online]. 2001 [cit. 2017-10-16]. Dostupné z: <http://measure.feld.cvut.cz/groups/diag/download/Wavelet-intro8859.pdf>
- [6] ADDISON, Paul S. The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance. New York: Taylor & Francis, c2002. ISBN 0750306920.
- [7] PATRICK FLANDRIN, PAULO GONCALVES a GABRIEL RILLING. Detrending and denoising with empirical mode decompositions.
- [8] T SRIKANTH, SA NAPPER a H GU. Assessment of Resampling Methodologies of Electrocardiogram Signals for Feature Extraction, Statistical and Neural Networks Applications. In: IEEE. 1998. ISBN 0276-6547.
- [9] S.D.H. SOEDIRDOJO, K. ULLAH a R. MERLETTI. Power Line Interference Attenuation in Multi-channel sEMG signals: Algorithms and Analysis. In: IEEE. 2015. ISBN 978-1-4244-9270-1.
- [10] REAZ, M. B. I., M. S. HUSSAIN a F. MOHD-YASIN. Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological Procedures Online* [online]. 2006, 8(1), 11-35 [cit. 2017-04-18]. DOI: 10.1251/bpo115. ISSN 14809222.
- [11] D. BALASUBRAMANIAM. In: IEEE. 2009. Implementation of ECG Signal Processing and Analysis Techniques in Digital Signal Processor based System. ISBN 978-1-4244-3599-9.
- [12] RASHMI PANDA a UMESH C. PATI. In: IEEE. 2012. Removal of Artifacts from Electrocardiogram Using Digital Filter. ISBN 978-1-4673-1515-9. UZZAL BISWAS a MD. MANIRUZZAMAN. In: IEEE. 2014. Removing Power Line Interference from ECG Signal Using Adaptive Filter and Notch Filter. ISBN 978-1-4799-4819-2.
- [13] SONAL K. JAGTAP a M. D. UPLANE. In: IEEE. 2012. The Impact of Digital Filtering to ECG Analysis: Butterworth Filter Application. ISBN 978-1-4577-2078-9.
- [14] PUNEET KUMAR JAIN a ANIL KUMAR TIWARI. An Adaptive Method for Shrinking of Wavelet Coefficients for Phonocardiogram Denoising. In: IEEE. 2016. ISBN 978-1-5090-4165-7.
- [15] MOHANNAD K. SABIR. PCG Signal Analysis using Teager Energy Operator & Autocorrelation function. In: IEEE. 2013. ISBN 978-1-4673-5214-7.
- [16] XIUMEI YANG, JIAHUA PAN, ZUXING ZHANG, LIBIN FANG, YUANXIA JI, YUN FAN a WEILIAN WANG. Analyzing the Phonocardiogram of ASD-Patient Based on Independent Component Analysis. Piscataway, NJ: IEEE Service Center, 2006. ISBN 0780397371.

- [17] XIEFENG CHENG, KEXUE SUN, XUEJUN ZHANG a CHENJUN SHE. Feature Extraction and Recognition Methods Based on Phonocardiogram. In: KEXUE SUN a CHENJUN SHE. IEEE. 2016. ISBN 978-1-4673-9379-9.
- [18] TAMAL CHAKRABARTI, SOURAV SAHA a ISHITA CHEL. Phonocardiogram signal analysis - practices, trends and challenges: a critical review. In: IEEE. 2015. ISBN 978-1-4799-6908-1.
- [19] EBRU YAVUZ a ÖNDER AYDEMİR. Olfaction Recognition by EEG Analysis Using Wavelet Transform Features. In: IEEE. 2016. ISBN 978-1-4673-9910-4.
- [20] H. VÉLEZ-PÉREZ, R. ROMO-VÁZQUEZ, R. RANTA, V. LOUIS-DORR a L. MAILLARD. EEG preprocessing for synchronization estimation and epilepsy lateralization. In: IEEE. 2011. ISBN 978-1-4244-4122-8.
- [21] R. ROMO-VAZQUEZ, R. RANTA, V. LOUIS-DORR a D. MAQUIN. EEG Ocular Artefacts and Noise Removal. In: IEEE. 2007. ISBN 1-4244-0788-5.
- [22] C. CORRADINO a M. BUCOLO. Automatic Preprocessing of EEG Signals in Long Time Scale. In: IEEE. 2015. ISBN 978-1-4244-9270-1.
- [23] DATTAPRASAD A. TORSE a VEENA V. DESAI E. Design of Adaptive EEG Preprocessing Algorithm for Neurofeedback System. In: IEEE. 2016. ISBN 978-1-5090-0396-9.
- [24] BYUNG S. KIM a SUN K. YOO. Motion Artifact Reduction in Photoplethysmography Using Independent Component Analysis. In: IEEE. 2006. ISBN 0018-9294.
- [25] BO PANG, MING LIU, XU ZHANG, PENG LI, ZHAOLIN YAO, XIAOHUI HU a HONGDA CHEN. Advanced EMD method using Variance Characterization for PPG with Motion Artifact. In: IEEE. 2016. ISBN 978-1-5090-2959-4.
- [26] CHIH-CHIN WU, SHU-HAN FAN, SHANG CHUANG, JIA-JU LIAO, CHIA-CHING CHOU a WAI-CHI FANG. A Wireless Photoplethysmography Signal Processing System for Long-term Monitoring. In: IEEE. 2016. ISBN 978-1-4673-8364-6.
- [27] K. VENU MADHAV, M. RAGHU RAM, E. HARI KRISHNA, K. NAGARJUNA REDDY a , K. ASHOKA REDDY5. A robust signal processing method for extraction of respiratory activity from artifact corrupted PPG signal. In: IEEE. 2011. ISBN 978-1-4244-9477-4.
- [28] GYAN C. AGARWAL a GERALD L. GOTTLIEB. An Analysis of the Electromyogram by Fourier, Simulation and Experimental Techniques. IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING. 1975, BME-22(3).
- [29] CHRISTOPHER WATFORD. Understanding ECG Filtering [online]. 2014. Dostupné z: <http://www.ems12lead.com/2014/03/10/understanding-ecg-filtering/>
- [30] SELIM R. BENBADIS. EEG Artifacts [online]. 2017. Dostupné z: <https://emedicine.medscape.com/article/1140247-overview#a3>
- [31] S. ABBASPOUR a A. FALLAH. Removing ECG Artifact from the Surface EMG Signal Using Adaptive Subtraction Technique. Journal of Biomedical Physics and Engineering [online]. 2014, 4(1), 33-38. ISSN 2251-7200.
- [32] CARLO J. DE LUCA, MIKHAIL KUZNETSOV, L. DONALD GILMORE a SERGE H. ROY. Inter-electrode spacing of surface EMG sensors: Reduction of crosstalk contamination during voluntary contractions. Journal of Biomechanics. 2011. DOI: 10.1016/j.jbiomech.2011.11.010.
- [33] DELSYS, Wereable sensors for movement sciences [online]. Dostupné z: <http://www.delsys.com/products/software/emgworks/sqm/factors/>

- [34] NUNO MIGUEL TAVARES COSTA E SILVA. Phonocardiogram Noise Detection in Realistic Environments. Porto, 2012. Diplomová práce. Universidade do Porto. Vedoucí práce Prof. Dr. Miguel Tavares Coimbra.
- [35] MOHAMED ELGENDI. On the Analysis of Fingertip Photoplethysmogram Signals. In: Current Cardiology Reviews [online]. 8. 2012, s. 14-25 [cit. 2018-01-07]. ISSN 1875-6557. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3394104/pdf/CCR-8-14.pdf>
- [36] MARK A. WICKERT, Introduction to Signals and Systems, ECE 2610 Lecture Notes, 2011.
- [37] STANISLAV OLIVÍK, Ukázka možností interpolace dat v softwaru Matlab [online], dostupné z <https://mat.fsv.cvut.cz/komisevstez/13/prispevky/olivik.pdf>

Seznam příloh

Příloha 1 – Příloha na CD/DVD:

1. Aplikace v Matlabu,
2. Příručka k aplikaci v Matlabu,
3. Aplikace v C#.